



TUGAS AKHIR - SS141501

**MODEL HIBRIDA ARIMAX DAN *DEEP NEURAL NETWORK* UNTUK PERAMALAN BEBAN LISTRIK JANGKA PENDEK AREA JAWA TENGAH DAN DIY**

**FIRDHA AMELIA TRYASTUTI**  
**NRP 062114 4000 0075**

**Dosen Pembimbing**  
**Dr. Suhartono**

**PROGRAM STUDI SARJANA**  
**DEPARTEMEN STATISTIKA**  
**FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA**  
**INSTITUT TEKNOLOGI SEPULUH NOPEMBER**





**TUGAS AKHIR - SS141501**

**MODEL HIBRIDA ARIMAX DAN *DEEP NEURAL NETWORK* UNTUK PERAMALAN BEBAN LISTRIK JANGKA PENDEK AREA JAWA TENGAH DAN DIY**

**FIRDHA AMELIA TRYASTUTI  
NRP 062114 4000 0075**

**Dosen Pembimbing  
Dr. Suhartono**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2018**







**FINAL PROJECT - SS 141501**

**HYBRID ARIMAX AND DEEP NEURAL NETWORK  
MODEL FOR SHORT TERM LOAD FORECASTING  
IN JAWA TENGAH AND DIY**

**FIRDHA AMELIA TRYASTUTI  
SN 062114 4000 0075**

**Supervisor  
Dr. Suhartono**

**UNDERGRADUATE PROGRAMME  
DEPARTMENT OF STATISTICS  
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCE  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2018**



## LEMBAR PENGESAHAN

### **MODEL HIBRIDA ARIMAX DAN *DEEP NEURAL NETWORK* UNTUK PERAMALAN BEBAN LISTRIK JANGKA PENDEK AREA JAWA TENGAH DAN DIY**

#### **TUGAS AKHIR**

Diajukan untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Sains  
pada  
Program Studi Sarjana Departemen Statistika  
Fakultas Matematika, Komputasi, dan Sains Data  
Institut Teknologi Sepuluh Nopember

Oleh :  
**Firdha Amelia Tryastuti**  
NRP. 062114 4000 0075

Disetujui oleh Pembimbing:

**Dr. Suhartono**  
NIP. 19710929 199512 1 001



Mengetahui,  
Kepala Departemen

**Dr. Suhartono**

NIP. 19710929 199512 1 001

SURABAYA, JULI 2018

*(Halaman ini sengaja dikosongkan)*

# **MODEL HIBRIDA ARIMAX DAN DEEP NEURAL NETWORK UNTUK PERAMALAN BEBAN LISTRIK JANGKA PENDEK AREA JAWA TENGAH DAN DIY**

**Nama Mahasiswa** : Firdha Amelia Tryastuti  
**NRP** : 0621144000 0075  
**Departemen** : Statistika  
**Dosen Pembimbing** : Dr. Suhartono

## **Abstrak**

*Listrik yang dibangkitkan harus langsung digunakan oleh konsumen sehingga diperlukan perencanaan dalam bentuk peramalan beban listrik. Terdapat berbagai macam model peramalan yang telah dikembangkan untuk melakukan peramalan beban listrik. Penelitian ini bertujuan untuk meramalkan beban listrik per setengah jam di wilayah Jateng dan DIY. Model hibrida ARIMAX-DNN akan dibandingkan dengan model ARIMAX dan model Deep Neural Network. Ketiga model ini akan diterapkan pada kajian simulasi dan kajian terapan untuk data beban listrik per setengah jam wilayah Jawa Tengah dan DIY periode 1 Januari 2013 sampai 31 Desember 2017 Untuk membandingkan ketiga model tersebut akan digunakan evaluasi kebaikan model RMSEP dan sMAPEP. Hasil pada kajian simulasi menunjukkan bahwa ARIMAX merupakan model terbaik pada horizon short dan model Hibrida ARIMAX-DNN merupakan model terbaik pada horizon medium dan long. Sedangkan pada data yang mengandung noise nonlinear model Hibrida ARIMAX-DNN merupakan model terbaik pada horizon short, medium, dan long. Pada kajian terapan menunjukkan model DNN baik untuk horizon short, medium dan long.*

**Kata Kunci : ARIMAX, Beban Listrik, Deep Neural Network, RMSEP, sMAPEP**

*(Halaman ini sengaja dikosongkan)*

# **HYBRID ARIMAX AND DEEP NEURAL NETWORK MODEL FOR SHORT TERM LOAD FORECASTING IN JAWA TENGAH AND DIY**

**Name : Firdha Amelia Tryastuti**  
**Student Number : 0621144000 0075**  
**Department : Statistics**  
**Supervisor : Dr. Suhartono**

## **Abstract**

*Electricity generated must be directly used by consumers so that the necessary planning in the form of electricity load forecasting. There are various forecasting models that have been developed to forecast electric loads. This study aims to predict electricity load per half hour in Central Java and DIY. This study will be forecasting with ARIMAX model on the first level and Deep Neural Network at the second level. The Hybrid ARIMAX-DNN model will be compared with ARIMAX model and Deep Neural Network model. These three models will be applied to simulation studies and applied studies for electricity load data per half hour of Central Java and DIY for the period January 1, 2013 to December 31, 2017. In this study each model will be applied to 48 series of 1826 data for each series. Evaluation of the goodness of the model used to compare the three models is RMSEP and sMAPEP. The results of the simulation study show that ARIMAX is the best model on the short horizon and the ARIMAX-DNN Hybrid model is the best model on medium and long horizons. While on the data containing nonlinear noise model Hybrid ARIMAX-DNN is the best model on short, medium, and long horizons. Applied studies show the DNN model on short, medium and long horizons.*

**Keywords: ARIMAX, Deep Neural Network, Load, RMSEP, sMAPEP**

*(Halaman ini sengaja dikosongkan)*



## KATA PENGANTAR

Puji syukur penulis panjatkan kehadirat Tuhan Yang Maha Esa yang telah melimpahkan rahmat dan kerunia-Nya, sehingga penulis dapat menyelesaikan Tugas Akhir dengan judul **“Model Hibrida ARIMAX dan *Deep Neural Network* untuk Peramalan Beban Listrik Jangka Pendek Area Jawa Tengah dan DIY”** dengan baik.

Dalam proses penyusunan Tugas Akhir ini tidak lepas dari bantuan, bimbingan, dan dukungan dari berbagai pihak. Maka dari itu, pada kesempatan ini penulis mengucapkan terima kasih kepada:

1. Bapak Dr. Suhartono selaku dosen pembimbing sekaligus Kepala Departemen Statistika ITS, yang telah meluangkan waktu memberikan bimbingan, saran, dukungan dan motivasi selama penyusunan Tugas Akhir
2. Bapak Dr. R. Mohamad Atok, S.Si, M.Si dan Ibu Santi Puteri Rahayu, Ph.D selaku dosen penguji yang telah memberikan banyak masukan bagi penulis.
3. Bapak Dr. Sutikno, M.Si selaku Ketua Program Studi Sarjana Statistika ITS yang membantu secara administrasi dalam proses penyusunan Tugas Akhir.
4. Bapak Budiono, Ibu Yofa dan seluruh pihak kantor PT.PLN (Persero) P2B-APB Wilayah Jawa Tengah dan DIY yang telah memberikan kepercayaan dan kesempatan kepada penulis untuk menganalisis data.
5. Kedua orang tua penulis serta keluarga besar yang telah memberikan doa nasihat, dukungan kepada penulis dalam menyelesaikan Tugas Akhir.
6. Teman-teman Statistika ITS angkatan 2014, Respect, yang selalu memberikan dukungan kepada penulis selama ini.
7. Semua pihak yang telah memberikan bantuan maupun dukungan yang tidak dapat disebutkan satu per satu dalam penyusunan Tugas Akhir ini.

Penulis menyadari Tugas Akhir ini masih banyak kekurangan. Besar harapan penulis untuk mendapatkan kritik dan saran yang membangun selalu penulis harapkan guna perbaikan di masa yang akan datang sehingga hasil dari Tugas Akhir ini memberikan manfaat bagi semua pihak

Surabaya, Juli 2018

Penulis

## DAFTAR ISI

	Halaman
<b>HALAMAN JUDUL</b> .....	i
<b>COVER PAGE</b> .....	iii
<b>LEMBAR PENGESAHAN</b> .....	v
<b>ABSTRAK</b> .....	vii
<b>ABSTRACT</b> .....	ix
<b>KATA PENGANTAR</b> .....	xi
<b>DAFTAR ISI</b> .....	xiii
<b>DAFTAR GAMBAR</b> .....	xv
<b>DAFTAR TABEL</b> .....	xviii
<b>DAFTAR LAMPIRAN</b> .....	xxi
<b>DAFTAR NOTASI</b> .....	xxii
<b>BAB I PENDAHULUAN</b> .....	1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	6
1.3 Tujuan.....	6
1.4 Manfaat.....	7
1.5 Batasan Masalah.....	7
<b>BAB II TINJAUAN PUSTAKA</b> .....	9
2.1 Analisis Deret Waktu ( <i>Time Series</i> ).....	9
2.2 <i>Autoregressive Integrated Moving Average</i> (ARIMA).....	9
2.3 ARIMAX.....	15
2.4 Pengujian Linearitas .....	17
2.5 <i>Neural Network</i> .....	18
2.6 Algoritma <i>Backpropagation</i> .....	20
2.7 <i>Deep Neural Network</i> .....	24
2.8 Model Hibrida .....	28
2.9 Pemilihan Model Terbaik.....	29
2.10 Peramalan Beban Listrik .....	30
2.11 Penelitian Sebelumnya .....	32
<b>BAB III METODOLOGI PENELITIAN</b> .....	35
3.1 Kajian Simulasi .....	35
3.2 Kajian Terapan .....	38

<b>BAB IV</b>	<b>ANALISIS DAN PEMBAHASAN .....</b>	<b>51</b>
4.1	Kajian Simulasi .....	51
4.2	Karakteristik Data Beban Listrik Per Setengah Jam	82
4.3	Permodelan Data Beban Listrik Per Setengah Jam Wilayah Jawa Tengah dan DIY .....	87
4.3.1	Permodelan dengan ARIMAX .....	87
4.3.2	Permodelan dengan Deep Neural Network .....	91
4.3.3	Permodelan dengan Hibrida ARIMAX-DNN .....	97
4.4	Perbandingan Model ARIMAX, DNN, dan Hibrida ARIMAX-DNN .....	101
<b>BAB IV</b>	<b>KESIMPULAN DAN SARAN.....</b>	<b>111</b>
5.1	Kesimpulan.....	111
5.2	Saran.....	112
<b>DAFTAR PUSTAKA</b>	<b>.....</b>	<b>113</b>
<b>LAMPIRAN</b>	<b>.....</b>	<b>119</b>
<b>BIODATA PENULIS</b>	<b>.....</b>	<b>277</b>

## DAFTAR GAMBAR

	Halaman
<b>Gambar 2.1</b>	Struktur FFNN Satu <i>Hidden Layer</i> ..... 19
<b>Gambar 2.2</b>	Struktur <i>Deep Neural Network</i> ..... 25
<b>Gambar 2.3</b>	Proses Listrik Disalurkan..... 30
<b>Gambar 3.1</b>	Langkah Analisis Kajian Terapan ..... 44
<b>Gambar 3.2</b>	Langkah Analisis Model ARIMAX..... 45
<b>Gambar 3.3</b>	Langkah Analisis Model <i>Deep Learning</i> ..... 46
<b>Gambar 3.4</b>	Proses ARIMAX..... 47
<b>Gambar 3.5</b>	Proses DNN ..... 48
<b>Gambar 3.6</b>	Proses Model Hibrida ARIMAX dan <i>Deep Neural Network</i> ..... 49
<b>Gambar 4.1</b>	Plot Data Beban Listrik Jam 04:00 untuk Komponen ..... 51
<b>Gambar 4.2</b>	<i>Scatter Plot</i> antara Noise ( $N_t$ ) dan Lag Noise ( $N_{t-1}$ ) ..... 52
<b>Gambar 4.3</b>	Plot <i>Time Series</i> Skenario 1 ..... 53
<b>Gambar 4.4</b>	Perbandingan Data Aktual dan Ramalan Beberapa Waktu untuk Simulasi Skenario 1 dengan Model ARIMAX ..... 56
<b>Gambar 4.5</b>	Plot PACF untuk Data Simulasi Skenario 1 pada jam 20:00..... 58
<b>Gambar 4.6</b>	Arsitektur DNN untuk Data Simulasi Skenario 1 pada jam 20:00..... 59
<b>Gambar 4.7</b>	Perbandingan Data Aktual Skenario 1 dan Ramalan dengan menggunakan model DNN. 60
<b>Gambar 4.8</b>	Arsitektur DNN pada Model Hibrida ARIMAX-DNN untuk Data Simulasi Skenario 1 pada jam 20:00 ..... 64
<b>Gambar 4.9</b>	Perbandingan Data Aktual Skenario 1 dan Ramalan dengan Menggunakan Model Hibrida ARIMAX-DNN ..... 64
<b>Gambar 4.10</b>	Plot <i>time series</i> Skenario 2 ..... 66

<b>Gambar 4.11</b>	Perbandingan Data Aktual dan Ramalan Beberapa Waktu untuk Simulasi Skenario 2 dengan Model ARIMAX .....	69
<b>Gambar 4.12</b>	Plot PACF untuk Data Simulasi Skenario 2 pada jam 20:00.....	71
<b>Gambar 4.13</b>	Arsitektur DNN untuk Data Simulasi Skenario 2 pada jam 20:00.....	72
<b>Gambar 4.14</b>	Perbandingan Data Aktual Skenario 2 dan Ramalan dengan menggunakan model DNN.	73
<b>Gambar 4.15</b>	Arsitektur DNN pada Model Hibrida ARIMAX-DNN untuk Data Simulasi Skenario 2 pada jam 20:00.....	76
<b>Gambar 4.16</b>	Perbandingan Data Aktual Skenario 2 dan Ramalan dengan Menggunakan Model Hibrida ARIMAX-DNN .....	77
<b>Gambar 4.17</b>	Perbandingan RMSEP untuk Masing-masing Skenario .....	80
<b>Gambar 4.18</b>	Perbandingan sMAPE untuk Masing-masing Skenario .....	80
<b>Gambar 4.19</b>	Plot <i>time series</i> Beban Listrik Per Setengah Jam Periode 2013-2017 .....	82
<b>Gambar 4.20</b>	Pola Pemakaian Listrik per Setengah Jam di Jateng-DIY peirode 2013-2017 .....	84
<b>Gambar 4.21</b>	Pola Pemakaian Listrik Harian di Jateng-DIY perode 2013-2017 .....	85
<b>Gambar 4.22</b>	Scaterplot antara Data Beban Listrik ( $Y_t$ ) dan Lag Data Beban Listrik ( $Y_{t-1}$ ) .....	86
<b>Gambar 4.23</b>	Perbandingan Data Beban Listrik jam 20:00 dan Ramalan dengan Menggunakan ARIMAX .....	90
<b>Gambar 4.24</b>	Plot PACF untuk Data Beban Listrik pada Jam 20:00 .....	92
<b>Gambar 4.25</b>	Arsitektur DNN untuk Data Beban Listrik Jam 20:00 .....	93

<b>Gambar 4.26</b>	Perbandingan Data Aktual Jam 20:00 dan Data Ramalan dengan menggunakan model DNN.....	94
<b>Gambar 4.27</b>	Perbandingan Data Aktual jam 20:00 dengan dengan Data Ramalan dengan menggunakan model Hibrida ARIMAX-DNN.....	98
<b>Gambar 4.28</b>	Arsitektur DNN pada Model Hibrida ARIMAX-DNN untuk Data Beban Listrik pada jam 20:00.....	99
<b>Gambar 4.29</b>	Hasil Model Terbaik untuk Masing-masing Horizon .....	104
<b>Gambar 4.30</b>	Plot Hasil Peramalan Beban Listrik Per Setengah Jam Periode 2018 .....	105
<b>Gambar 4.31</b>	Scatterplot Standar Deviasi dan RMSEP.....	109

*(Halaman ini sengaja dikosongkan)*



## DAFTAR TABEL

	Halaman
<b>Tabel 2.1</b> Identifikasi Order Model AR dan MA.....	10
<b>Tabel 2.2</b> Perbandingan MAPEP dan sMAPEP.....	29
<b>Tabel 2.3</b> Rangkuman Penelitian Sebelumnya .....	32
<b>Tabel 3.1</b> Pembobotan untuk Komponen Musiman Harian	36
<b>Tabel 3.2</b> Daftar Hari Libur Selain Minggu Tahun 2013 hingga 2017 .....	39
<b>Tabel 3.3</b> Struktur Data Penelitian.....	41
<b>Tabel 4.1</b> Estimasi Parameter Regresi <i>Time Series</i> Skenario 1 .....	54
<b>Tabel 4.2</b> Hasil Uji White Noise dan Normalitas pada Residual Skenario 1 .....	55
<b>Tabel 4.3</b> Komponen ARIMA pada Model ARIMAX untuk Data Simulasi Skenario 1 Masing-masing waktu	56
<b>Tabel 4.4</b> Arsitektur untuk Permodelan DNN pada Skenario 1 .....	60
<b>Tabel 4.5</b> Arsitektur untuk Model Hibrida ARIMAX-DNN pada Skenario 1.....	63
<b>Tabel 4.6</b> Estimasi Parameter Regresi <i>Time Series</i> Skenario 2 .....	67
<b>Tabel 4.7</b> Hasil Uji White Noise dan Normalitas pada Residual Skenario 2 .....	68
<b>Tabel 4.8</b> Komponen ARIMA pada Model ARIMAX untuk Data Simulasi Skenario 2 Masing-masing waktu	69
<b>Tabel 4.9</b> Arsitektur untuk Permodelan DNN pada Skenario 2 .....	73
<b>Tabel 4.10</b> Arsitektur Permodelan Hibrida ARIMAX-DNN pada Skenario 2.....	77
<b>Tabel 4.11</b> Perbandingan RMSEP untuk Masing-masing Skenario .....	79
<b>Tabel 4.12</b> Perbandingan sMAPE untuk Masing-masing Skenario .....	79
<b>Tabel 4.13</b> Metode Terbaik untuk Masing-masing Skenario	81

<b>Tabel 4.14</b>	Statistika Deskriptif data Beban Listrik Jateng-DIY per Setengah Jam .....	83
<b>Tabel 4.15</b>	Estimasi Parameter Regresi <i>Time Series</i> Data Beban Listrik 20:00.....	87
<b>Tabel 4.16</b>	Hasil Uji White Noise dan Normalitas pada Residual.....	88
<b>Tabel 4.17</b>	Komponen ARIMA pada Model ARIMAX Data Beban Listrik untuk Masing-Masing Waktu.....	90
<b>Tabel 4.18</b>	Arsitektur untuk Permodelan DNN pada Data Beban Listrik.....	94
<b>Tabel 4.19</b>	Arsitektur untuk Permodelan Hibrida ARIMAX-DNN pada Data Beban Listrik .....	99
<b>Tabel 4.20</b>	Perbandingan RMSEP untuk Masing-masing Model .....	101
<b>Tabel 4.21</b>	Perbandingan sMAPE untuk Masing-masing Model .....	102
<b>Tabel 4.22</b>	Hubungan Pola Data dengan Model Terbaik .....	107
<b>Tabel 4.23</b>	Hubungan Karakteristik Data dengan RMSEP...	107

## DAFTAR LAMPIRAN

	Halaman
<b>Lampiran 1</b> Hasil ARIMAX pada Skenario 1 .....	119
<b>Lampiran 2</b> Arsitektur DNN Data Simulasi Skenario 1 .....	127
<b>Lampiran 3</b> Arsitektur Hibrida ARIMAX-DNN Data Simulasi Skenario 1.....	130
<b>Lampiran 4</b> Hasil ARIMAX pada Skenario 2 .....	133
<b>Lampiran 5</b> Arsitektur DNN Data Simulasi Skenario 2 .....	141
<b>Lampiran 6</b> Arsitektur Hibrida ARIMAX-DNN Data Simulasi Skenario 2.....	144
<b>Lampiran 7</b> Hasil Perhitungan RMSEP Horizon untuk Data Simulasi.....	147
<b>Lampiran 8</b> Hasil ARIMAX pada Data Beban Listrik .....	148
<b>Lampiran 9</b> Jumlah Otlier untuk masing-masing Waktu.....	207
<b>Lampiran 10</b> Uji White Data Beban Listrik Jateng-DIY .....	208
<b>Lampiran 11</b> Arsitektur DNN Data Simulasi .....	214
<b>Lampiran 12</b> Arsitektur Hibrida ARIMAX-DNN Data Beban Listrik.....	238
<b>Lampiran 13</b> Perhitungan Horizon Data Beban Listrik.....	262
<b>Lampiran 14</b> Syntax ARIMAX .....	266
<b>Lampiran 15</b> Syntax DNN.....	268
<b>Lampiran 16</b> Syntax Uji White.....	271
<b>Lampiran 17</b> Syntax Hibrida ARIMAX-DNN .....	272
<b>Lampiran 18</b> Surat Keterangan Pengambilan Data Surat .....	275

*(Halaman ini sengaja dikosongkan)*

## DAFTAR NOTASI

### ARIMAX

$a_t$	<i>Residual</i> pada waktu ke $t$
$B$	<i>Backshift</i> operator
$Y_t$	Data time series dengan indeks $t$
$\phi_p(B)$	Koefisien komponen AR non musiman dengan orde $p$
$\Phi_P(B)^s$	Koefisien komponen AR musiman $S$ dengan orde $P$
$\theta_q(B)$	Koefisien komponen MA non musiman dengan orde $q$
$\Theta_Q(B)^s$	Koefisien komponen MA musiman $S$ dengan orde $Q$
$T_t$	komponen untuk tren linier
$D_t^w$	komponen untuk pola musiman harian
$D_t^V$	komponen untuk variasi kalender.

### Neural Network

$\hat{Y}$	Variabel <i>output</i>
$b^o$	Bias neuron pada lapisan <i>output</i>
$w_j^o$	Bobot dari neuron ke- $j$ pada lapisan tersembunyi yang menuju neuron pada lapisan <i>output</i>
$f_j^1$	Fungsi aktivasi neuron ke- $j$ pada lapisan tersembunyi ke- $1$
$b_j^1$	Bias neuron ke- $j$ pada lapisan tersembunyi ke- $1$
$w_{ij}^1$	Bobot <i>input</i> ke- $i$ yang menuju ke neuron ke- $j$ pada lapisan tersembunyi ke- $1$
$Z_{it}$	Variabel <i>input</i>

### ***Deep Neural Network***

$\hat{Y}$	Variabel <i>output</i>
$b^o$	Bias neuron pada lapisan <i>output</i>
$w_k^o$	Bobot dari neuron ke- $k$ pada lapisan tersembunyi yang menuju neuron pada lapisan <i>output</i>
$f_k^2$	Fungsi aktivasi neuron ke- $j$ pada lapisan tersembunyi ke-2
$b_k^2$	Bias neuron ke- $k$ pada lapisan tersembunyi ke-2
$w_{jk}^2$	Bobot <i>input</i> ke- $j$ yang menuju ke neuron ke- $k$ pada lapisan tersembunyi ke-2
$f_j^1$	Fungsi aktivasi neuron ke- $j$ pada lapisan tersembunyi ke-1
$b_j^1$	Bias neuron ke- $j$ pada lapisan tersembunyi ke-1
$w_{ij}^1$	Bobot <i>input</i> ke- $i$ yang menuju ke neuron ke- $j$ pada lapisan tersembunyi ke-1
$Z_{it}$	Variabel <i>input</i>

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Saat ini listrik sudah menjadi kebutuhan pokok bagi masyarakat. Listrik merupakan energi yang dapat digunakan sebagai penerangan ataupun alat elektronik lainnya. Energi listrik yang dibangkitkan (dihasilkan) tidak dapat disimpan, melainkan langsung habis digunakan oleh konsumen. Beban atau yang sering disebut sebagai *demand*, merupakan besaran kebutuhan tenaga listrik yang dinyatakan dengan MWh, MW atau MVA tergantung dengan konteksnya (ESDM, 2016). PT. PLN merupakan perusahaan milik negara yang menyediakan listrik bagi masyarakat baik untuk sektor industri maupun sektor rumah tangga. PT. PLN sendiri dibagi menjadi beberapa unit yang dibedakan berdasarkan tugas dan fungsinya salah satunya adalah PT. PLN P2B – APB Jateng dan DIY. PT. PLN P2B – APB Jateng dan DIY Semarang bertugas sebagai koordinasi pemeliharaan, pembagian beban yang ekonomis, pengaturan frekuensi, mengatur prosedur mengatasi gangguan. Dalam memenuhi kebutuhan listrik untuk masyarakat, PLN mendapatkan pasokan listrik dari pembangkit PLN sendiri dan IPP (*Independent Power Producer*). Sistem kelistrikan Jawa Tengah dan DIY saat ini memiliki tiga sub sistem yaitu Tanjung Jati, Ungaran, dan Pedan.

Saat ini Jawa Tengah menjadi salah satu tujuan tempat relokasi untuk beberapa perusahaan dari industri padat karya (Rini, 2017). Kawasan industri yang sedang dipersiapkan di Jawa Tengah diantaranya berada di daerah Kendal. Ketersediaan listrik dinilai menjadi kebutuhan utama dalam pengembangan kawasan industri untuk dapat menarik investasi sekaligus menggerakkan perekonomian daerah. Karena itu, harus dipastikan pasokan energi listrik dapat memberikan layanan yang prima (Koran SINDO, 2017). PT. PLN menyiapkan pasokan energi listrik sebesar 270 mVA untuk memenuhi kebutuhan sejumlah pelanggan potensial di sektor industri menengah dan besar, di wilayah Jawa Tengah dan

DI Yogyakarta. Selain proyek 35 ribu MW, PLN juga akan membangun pembangkit dengan total daya 15 ribu MW di Jawa. Jadi, PLN siap dalam melayani suplai listrik bagi industri dan masyarakat. Dengan penambahan pasokan listrik untuk industri di Jawa Tengah dan Yogyakarta diharapkan mampu memenuhi kebutuhan pelanggan (Pujangga, 2017). Oleh karena itu, diperlukan perencanaan operasi berkaitan dengan perkiraan beban sebagai dasar perencanaan yang dapat digunakan untuk membuat rencana ke depan seperti rencana pengembangan pembangkitan, rencana transmisi dan gardu induk, rencana distribusi dan rencana pengembangan sistem kelistrikan. Salah satu cara yang dapat digunakan PT. PLN dalam perencanaan operasi dengan menggunakan peramalan konsumsi beban listrik.

Penelitian-penelitian yang pernah dilakukan untuk peramalan beban listrik jangka pendek diantaranya penelitian yang dilakukan Eljazzar dan Hemayed (2017) melakukan penelitian dengan menggunakan model ARIMA dan ANN dengan *Adaptive Fourier Series* untuk meningkatkan keakurasian dari hasil ramalan per jam. Pada penelitian tersebut data memiliki pola musiman untuk harian, mingguan, tahunan, dan mempertimbangkan efek dari hari khusus misalnya hari libur dalam peramalannya. Dari penelitian tersebut diketahui bahwa model ANN ditingkatkan dengan menambahkan lebih banyak koefisien pada deret Fourier lebih baik dibandingkan model ARIMA. Penelitian mengenai peramalan beban listrik jangka pendek juga dilakukan oleh Karthika dkk. (2017) dengan menggunakan model Hibrida ARIMA-SVM. Pada penelitian tersebut diperoleh dengan melakukan deteksi *outlier*, SMAPE dari hasil peramalan dapat diperkecil. Data yang digunakan pada penelitian ini mengandung musiman hari dan pada penelitian ini akan mempertimbangkan suhu udara dan hari dalam minggu dalam analisis. Hasil peramalan jangka pendek beban listrik dengan model ARIMA-SVM akan menghasilkan performa yang lebih baik dibandingkan model individu ARIMA dan SVM. Selain itu, He (2017) melakukan peramalan beban listrik jangka pendek dengan membandingkan



beberapa model diantaranya linear regresi, SVR, DNN, CNN dan RNN, dan Paralel CNN dan RNN. Dari penelitian tersebut dapat diketahui bahwa model *deep learning* dapat menghasilkan akurasi yang lebih baik dibanding model lain dan Paralel CNN dan RNN mampu mengurangi hampir 5% dari MAPE dan MAE jika dibandingkan dengan model lain. Franse (2017) melakukan peramalan beban listrik jangka pendek untuk kasus di Wales dan Inggris. Pada penelitian tersebut Franse menggunakan model SARIMA dan tiga kombinasi model Holt-Winter. Dari penelitian tersebut diketahui bahwa model *double seasonal* Holt-Winter dengan pengaturan AR lebih baik dibandingkan dengan model lain. Ozerdem dkk. (2017) melakukan peramalan beban listrik jangka pendek dengan *Particle Swarm Optimization Neural Network*. Pada penelitian ini membandingkan model PSO dan *Backpropagation Neural Network*.

Di Indonesia juga terdapat penelitian mengenai peramalan jangka pendek untuk beban listrik misalnya penelitian yang dilakukan oleh Dwisatya dan Kirom (2016). Pada penelitian tersebut dilakukan prediksi beban listrik jangka pendek untuk 3 tipe hari yaitu hari kerja, hari libur akhir pekan, dan hari libur nasional dengan model Jaringan Syaraf Tiruan (JST) menggunakan algoritma *feedforwardbackpropagation*. Khusna dan Suhartono (2012) melakukan *pendekatan Percentile Error Bootstrap* pada model *Double Seasonal Holt Winters*, *Double Seasonal* ARIMA, dan *Naive* untuk peramalan beban listrik jangka pendek di Jawa Timur dan Bali. Hasil penelitian tersebut menunjukkan bahwa terbaik untuk peramalan beban listrik jangka pendek area Jawa Timur-Bali adalah model DSARIMA dengan interval prediksi yang dikonstruksi menggunakan pendekatan *percentile error bootstrap*. Peramalan konsumsi listrik jangka pendek juga pernah dilakukan oleh Suhartono dan Endharta (2009) dengan ARIMA musiman ganda dan ELMAN-Recurrent Neural Network untuk kasus di Mengare Gresik. Pada penelitian tersebut diperoleh kesimpulan Elman-RNN merupakan model terbaik untuk peramalan konsumsi listrik per jam jangka pendek di Mengare

Gresik. Penelitian peramalan listrik untuk studi kasus area Jawa Tengah dan DIY pernah dilakukan oleh Pradipika dkk. (2017) juga melakukan penelitian peramalan listrik jangka pendek untuk studi kasus area Jawa Tengah dan DIY. Penelitian tersebut menggunakan model peramalan Jaringan Saraf Tiruan-Algoritma Genetika. Dari penelitian tersebut didapatkan hasil peramalan JST-AG dengan jumlah 94 neuron pada lapisan tersembunyi memiliki nilai MAPE yang paling baik yaitu 1,412 %, sedangkan nilai MAPE hasil peramalan yang digunakan PLN adalah sebesar 1,917 %. Selain itu Sari dkk. (2007) juga melakukan penelitian mengenai peramalan keutuhan beban listrik jangka pendek menggunakan jaringan syaraf tiruan *Backpropagation*. Untuk pola data listrik jangka pendek di area Jawa Tengah dan DIY menunjukkan konsumsi listrik masyarakat Jawa Tengah & DIY yang tidak merata sepanjang hari. Siklus tersebut mengalami penyimpangan di hari Minggu, hari libur, dan jika ada kegiatan sosial lainnya. Berdasarkan penelitian tersebut didapatkan hasil MAPE peramalan beban selama periode 17-23 Juli 2006, 1 Januari 2006, 17 Agustus 2006 dan 25 Desember 2006 dengan model Aplikasi Jaringan Syaraf Tiruan adalah 2,394 % dan MAPE peramalan PLN adalah 2,567%. MAPE peramalan beban satu jam ke depan pada tanggal 10 Juni 2003 adalah 3,08%, MAPE peramalan PLN adalah 1,611 %, dan MAPE peramalan JST adalah 2,112 % .

*Deep Learning* merupakan cabang ilmu dari *machine learning* berbasis *artificial Neural Network*. *Deep Learning* memiliki struktur yang sama dengan NN namun yang membedakan adalah terdapat lebih dari satu hidden layer pada *Deep Learning*. Pada penelitian ini akan digunakan pengembangan dari NN yaitu FFDNN (*Feed Forward Deep Neural Network*). DNN memiliki kemampuan abstraksi fitur pola *input* dan *output* yang lebih baik dan dapat menangani tugas yang kompleks dengan akurasi yang tinggi (Hossen dkk., 2017). Banyak penelitian yang dilakukan dengan menggunakan model DNN terutama *Feed Forward Deep Neural Network* diantaranya penelitian yang dilakukan oleh Din dan Marnerides (2017) untuk kasus beban

listrik jangka pendek. Data yang digunakan pada penelitian tersebut adalah beban listrik per jam dan suhu periode 2007 sampai 2017. Pola data penelitian ini menunjukkan musiman untuk harian, mingguan, dan konsumsi listrik tiap minggu dipengaruhi oleh suhu. Din dan Marnerides menggunakan dan membandingkan dua model DNN yaitu FFDNN dan RDNN serta didapatkan hasil bahwa model peramalan menggunakan FFDNN lebih baik dibandingkan dengan RDNN. Penelitian ini juga terlebih dahulu melakukan *feature extraction* berbasis penerapan *the joint time-frequency* (TF) yang dapat memperbaiki level akurasi peramalan statistik. Model FFDNN juga dapat digunakan untuk melakukan peramalan cuaca seperti penelitian yang dilakukan oleh Nagaselvi dan Deepa (2015). Penelitian ini menerapkan model FFDNN dan membandingkan dengan model ANN serta menerapkan teknik fuzzy untuk menghapus data *outlier* yang ada sebagai langkah pada *pre-processing data*. Pada penelitian ini menunjukkan model FFDNN untuk peramalan cuaca menghasilkan akurasi yang lebih tinggi dibandingkan peramalan cuaca dengan ANN.

Berdasarkan data konsumsi beban listrik jangka pendek area Jawa Tengah dan DIY, rata-rata beban listrik per setengah jam memiliki fluktuasi yang cukup tinggi. Selain itu, berdasarkan pola data yang ada, penggunaan beban listrik menurun pada hari-hari tertentu misalnya beberapa hari menjelang hingga beberapa hari setelah Hari Raya Idul Fitri. Pada data konsumsi beban listrik jangka pendek area Jawa Tengah dan DIY diindikasikan memiliki pola tren, musiman, pengaruh dari efek variasi kalender yaitu Hari Raya Idul Fitri, dan *nonlinear*. Dikarenakan adanya permasalahan tersebut dan pertimbangan dari penelitian yang ada, penelitian ini akan dilakukan peramalan dengan model hibrida ARIMAX dan *Deep Neural Network*. Penelitian ini akan dilakukan peramalan dengan model ARIMAX pada level pertama dan *Deep Neural Network* pada level kedua. Penggunaan model ARIMAX pada level pertama akan menangkap pola linear pada data dan pola musiman tahunan, pengaruh hari dalam seminggu, dan pengaruh dari hari khusus misalnya hari libur nasional. Oleh karena itu, akan

digunakan model *Deep Neural Network* untuk mengatasi kelemahan pada ARIMAX yang tidak bisa menangani masalah *nonlinear* pada data. Selain itu, penggunaan model hibrida ARIMAX dan *Deep Neural Network* diharapkan mampu meningkatkan keakurasian pada hasil peramalan data konsumsi beban listrik serta penelitian ini dapat menjadi pertimbangan untuk PLN dalam memutuskan kebijakan terutama dalam hal perencanaan pembelian atau pembangkitan tenaga listrik.

## 1.2 Rumusan Masalah

Pada data beban listrik jangka pendek area Jawa Tengah dan DIY diindikasikan memiliki pola tren, musiman, pengaruh dari efek variasi kalender yaitu Hari Raya Idul Fitri, dan *nonlinear*. Oleh karena itu, diperlukan analisis dengan model yang mampu menangkap pola tersebut sehingga mampu meningkatkan keakurasian dalam model peramalan. Secara umum permasalahan dari penelitian ini mengenai bagaimana peramalan beban listrik jangka pendek area Jateng dan DIY. Sebelum dilakukan peramalan beban listrik akan dilakukan kajian simulasi terkait peramalan dengan model ARIMAX, *Deep Neural Network* dan Hibrida ARIMAX dan *Deep Neural Network*. Selanjutnya akan dilakukan dengan analisis dengan statistika deskriptif dari data beban listrik jangka pendek area Jawa Tengah dan DIY. Selanjutnya akan dilakukan peramalan dengan model ARIMAX, *Deep Neural Network* dan Hibrida ARIMAX dan *Deep Neural Network*. Kemudian dari ketiga model yang telah dihasilkan tersebut dibandingkan tingkat keakurasiannya.

## 1.3 Tujuan

Berdasarkan rumusan masalah yang telah disusun, tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut:

1. Mengetahui pebandingan model ARIMAX, *Deep Neural Network*, dan Hibrida ARIMAX dan *Deep Neural Network* dari kajian simulasi.
2. Mengetahui karakteristik data beban listrik jangka pendek area Jawa Tengah dan DIY.

3. Mendapatkan model ARIMAX, *Deep Neural Network*, dan Hibrida ARIMAX dan *Deep Neural Network* untuk meramalkan data beban listrik jangka pendek area Jawa Tengah dan DIY.
4. Mengetahui perbandingan akurasi peramalan model ARIMAX, *Deep Neural Network*, dan hibrida ARIMAX dan *Deep Neural Network* pada data beban listrik jangka pendek area Jawa Tengah dan DIY.

#### **1.4 Manfaat**

Manfaat dari penelitian ini adalah sebagai berikut:

1. Peneliti mampu menerapkan teori analisis deret waktu menggunakan hibrida ARIMAX dan *Deep Neural Network* untuk meramalkan beban listrik wilayah Jateng dan DIY.
2. Menambah pengetahuan bagi pembaca mengenai model peramalan hibrida ARIMAX dan *Deep Neural Network*.
3. Membantu memberikan masukan bagi PT PLN (Persero) dalam perencanaan operasional.

#### **1.5 Batasan Masalah**

Terdapat beberapa batasan masalah dalam penelitian ini diantaranya batasan pada data yaitu data yang digunakan adalah data beban listrik jangka pendek per setengah jam area Jawa Tengah dan DIY periode Januari 2013 sampai dengan Desember 2017. Model yang digunakan adalah hibrida ARIMAX dan *Deep Neural Network*. Variabel *dummy* yang digunakan adalah *dummy* hari, dan efek hari khusus.

*(halaman sengaja dikosongkan)*

## BAB II

### TINJAUAN PUSTAKA

Bagian ini akan membahas beberapa kajian pustaka yang digunakan untuk menyelesaikan permasalahan mengenai peramalan beban listrik jangka pendek area Jawa Tengah dan DIY.

#### 2.1 Analisis Deret Waktu (*Time Series*)

Analisis *Time series* adalah analisis terhadap serangkaian pengamatan yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu kejadiannya dengan interval waktu yang tertentu (Wei, 2006 : 1). Tujuan dari analisis deret waktu (*time series*) adalah untuk memahami dan memodelkan mekanisme stokastik dari data observasi dan untuk meramalkan nilai masa depan berdasarkan data masa lalu (Cryer & Chan, 2008 :1).

#### 2.2 Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA adalah salah satu model *time series* yang dapat digunakan pada data yang stasioner. Model ARIMA dapat digunakan pada data dengan pola non musiman dan musiman. Apabila pada suatu data mengandung pola non musiman dan musiman, model ARIMA dapat dituliskan dengan ARIMA  $(p,d,q)(P,D,Q)^S$  dengan persamaan sebagai berikut:

$$\phi_p(B)\Phi_P(B)^s(1-B)^d(1-B^s)^D Y_t = \theta_q(B)\Theta_Q(B^s)a_t \quad (2.1)$$

dengan

$p, d, q$  : order AR ( $p$ ), order *difference* ( $d$ ), order MA ( $q$ ) untuk pola non musiman

$P, D, Q, S$  : order AR ( $P$ ), order *difference* ( $D$ ), order MA ( $Q$ ) untuk pola musiman  $S$  jumlah periode musiman

$\phi_p(B)$  : koefisien komponen AR non musiman dengan orde  $p$

- $\Phi_p(B)^s$  : koefisien komponen AR musiman  $S$  dengan orde  $P$   
 $\theta_q(B)$  : koefisien komponen MA non musiman dengan orde  $q$   
 $\Theta_Q(B^s)$  : koefisien komponen MA musiman  $S$  dengan orde  $Q$   
 $a_t$  : *residual* pada waktu ke- $t$ .

### 2.2.1 Tahap Identifikasi

Pada tahap ini dilakukan identifikasi pola untuk mengetahui model ARIMA. Model ARIMA dari suatu *time series* dapat dilakukan dengan melihat grafik *ACF* dan *PACF*. Sebelum dilakukan identifikasi model dengan grafik *ACF* dan *PACF*, data harus sudah stasioner dalam varians dan mean. Berikut merupakan identifikasi order model *AR* dan *MA* dengan plot *ACF* dan *PACF* (Bowerman & O'Connel, 1993 : 572-574).

**Tabel 2.1** Identifikasi Order Model AR dan MA

Model	<i>ACF</i>	<i>PACF</i>
AR ( $p$ )	Turun cepat secara eksponensial	<i>Cut off after lag p</i>
MA ( $q$ )	<i>Cut off after lag q</i>	Turun cepat secara eksponensial
AR ( $p$ ) atau MA( $q$ )	<i>Cut off after lag q</i>	<i>Cut off after lag p</i>
ARMA ( $p, q$ )	Turun cepat secara eksponensial	Turun cepat secara eksponensial
AR ( $P$ ) <sup>s</sup>	Turun cepat secara eksponensial pada lag musiman	<i>Cut off after lag PS</i>
MA ( $Q$ ) <sup>s</sup>	<i>Cut off after lag QS</i>	Turun cepat secara eksponensial pada lag musiman
AR ( $P$ ) <sup>s</sup> atau MA( $Q$ ) <sup>s</sup>	<i>Cut off after lag QS</i>	<i>Cut off after lag PS</i>
ARMA ( $P, Q$ ) <sup>s</sup>	Turun cepat secara eksponensial pada lag musiman	Turun cepat secara eksponensial pada lag musiman



### 2.2.2 Estimasi Parameter

Setelah mengidentifikasi model dilakukan estimasi parameter. Estimasi parameter ini dilakukan untuk menaksir parameter model yang telah kita tentukan. Salah satu metode yang dapat dilakukan untuk mengestimasi parameter adalah *conditional least square* (CLS). Misalnya akan dilakukan estimasi parameter pada mode AR(1). Persamaan model AR(1) dapat ditulis sebagai berikut (Cryer & Chan, 2008 : 154-155):

$$Y_t - \mu = \phi(Y_{t-1} - \mu) + a_t \quad (2.2)$$

dari persamaan di atas dapat diubah menjadi persamaan model error, yaitu:

$$a_t = (Y_t - \mu) - \phi(Y_{t-1} - \mu) \quad (2.3)$$

dan persamaan jumlah kuadrat error yang dirumuskan sebagai berikut:

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Y_t - \mu) - \phi(Y_{t-1} - \mu)]^2. \quad (2.4)$$

Langkah selanjutnya adalah mengestimasi  $\phi$  dan  $\mu$  menggunakan prinsip *least square* yaitu dengan meminimalkan  $S_c(\phi, \mu)$  terhadap  $\phi$  dan  $\mu$  kemudian masing-masing persamaan ekuivalen dengan nol seperti persamaan berikut:

$$\frac{\partial S_c}{\partial \mu} = \sum_{t=2}^n 2[(Y_t - \mu) - \phi(Y_{t-1} - \mu)](-1 + \phi) = 0 \quad (2.5)$$

$$\frac{\partial S_c}{\partial \phi} = \sum_{t=2}^n 2[(Y_t - \mu) - \phi(Y_{t-1} - \mu)](-Y_{t-1} + \mu) = 0. \quad (2.6)$$

Sehingga dari persamaan di atas didapatkan hasil taksiran  $\mu$  seperti berikut:

$$\mu = \frac{1}{(n-1)(1-\phi)} \left[ \sum_{t=2}^n Y_t - \phi \sum_{t=2}^n Y_{t-1} \right]. \quad (2.7)$$

Untuk  $n$  yang besar,

$$\frac{1}{n-1} \sum_{t=2}^n Y_t \approx \frac{1}{n-1} \sum_{t=2}^n Y_{t-1} \approx \bar{Y}. \quad (2.8)$$

Sehingga dapat ditulis  $\hat{\mu} = \bar{Z}$ . Sedangkan untuk  $\phi$ , didapatkan hasil taksiran seperti berikut:

$$\hat{\phi} = \frac{\sum_{t=2}^n [(Y_t - \bar{Y}) - \phi(Y_{t-1} - \bar{Y})]}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2}. \quad (2.9)$$

Selanjutnya, model peramalan yang diperoleh akan diuji signifikansi parameter. Hipotesis yang digunakan untuk pengujian signifikansi parameter pada model AR adalah sebagai berikut:

$$H_0 : \phi_i = 0$$

$$H_1 : \phi_i \neq 0 \text{ dengan } i = 1, 2, \dots, p$$

Statistik uji yang digunakan adalah.

$$t_{hitung} = \frac{\hat{\phi}_i}{SE(\hat{\phi}_i)} \quad (2.10)$$

dimana  $SE(\hat{\phi}_i)$  merupakan *standard error* dari parameter model AR. Tolak  $H_0$  apabila  $|t_{hitung}| > t_{\alpha/2, n-n_p}$  atau  $p_{value} < \alpha$  dengan  $n$  merupakan banyaknya pengamatan pada data *time series* dan  $n_p$  merupakan banyaknya parameter.

Selanjutnya hipotesis yang digunakan untuk pengujian signifikansi parameter pada model MA adalah sebagai berikut:

$$H_0 : \theta_j = 0$$

$$H_1 : \theta_j \neq 0 \text{ dengan } j = 1, 2, \dots, q$$

Statistik uji yang digunakan adalah.

$$t_{hitung} = \frac{\hat{\theta}_j}{SE(\hat{\theta}_j)} \quad (2.11)$$

dimana  $SE(\hat{\theta}_j)$  merupakan *standard error* dari parameter model AR. Tolak  $H_0$  apabila  $|t_{hitung}| > t_{\alpha/2, n-n_p}$  atau  $p_{value} < \alpha$  dengan  $n$  merupakan banyaknya pengamatan pada data *time series* dan  $n_p$  merupakan banyaknya parameter.

### 2.2.3 Cek Diagnosa

Setelah berhasil mengestimasi nilai-nilai parameter dari model *ARIMA* yang ditetapkan sementara, selanjutnya perlu dilakukan pemeriksaan diagnosa untuk membuktikan bahwa model tersebut cukup memadai (Makridakis, S., Wheelwright, S.C., & McGee, V.E, 1998 : 411). Untuk pemeriksaan diagnosa dilakukan uji asumsi error white noise dan berdistribusi normal.

Residual dikatakan white noise apabila residual telah memenuhi asumsi identik dan indepeden. Pengujian asumsi identik dilakukan dengan menggunakan uji *Lagrange Multiplier*. Uji *Lagrange Multiplier* bertujuan untuk mendeteksi adanya kasus heteroskedastisitas pada residual atau efek ARCH. Misalkan  $\hat{a}_t = \hat{\varepsilon}_t$ , dimana  $\hat{\varepsilon}_t$  merupakan deret yang akan diuji apakah terdapat efek ARCH. Persamaan untuk model AR ( $s$ ) untuk  $\hat{\varepsilon}_t^2$  adalah sebagai berikut (Wei, 2006: 369-370):

$$\hat{\varepsilon}_t^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_{t-1}^2 + \alpha_2 \hat{\varepsilon}_{t-2}^2 + \dots + \alpha_s \hat{\varepsilon}_{t-s}^2 + a_t, \quad (2. 12)$$

dimana  $t = s+1, s+2, \dots, n$ . Hipotesis yang digunakan dalam pengujian ini adalah sebagai berikut:

$H_0$  :  $\alpha_1 = \alpha_2 = \dots = \alpha_s = 0$  (residual indetik)

$H_1$  : Minimal ada satu  $\alpha_j \neq 0$   $j = 1, 2, 3, \dots, s$  (residual tidak identik)

Statistik uji dapat dilakukan menggunakan.

$$(n^* - s)R^2 \quad (2. 13)$$

dengan  $n^*$  adalah banyaknya pengamatan dan  $R^2$  adalah besarnya kontribusi varians *error* yang dapat dijelaskan data deret waktu sebelumnya. Keputusan tolak  $H_0$  jika  $(n-s)R^2 > \chi_{\alpha,q}^2$  atau

$$P_{value} < \alpha.$$

Untuk pengujian asumsi independen dilakukan dengan menggunakan uji Ljung-Box dengan hipotesis (Wei, 2006: 153):

$H_0$  :  $\rho_1 = \rho_2 = \dots = \rho_K = 0$  (residual bersifat independen)

$H_1$  : Minimal ada satu  $\rho_K \neq 0$  dengan  $i = 1, 2, \dots, K$  (residual tidak independen)

Statistik uji dapat dilakukan menggunakan.

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k}, \quad n > k. \quad (2.14)$$

Keputusan tolak  $H_0$  apabila  $Q > \chi^2_{(\alpha, (K-p-q))}$  atau  $P_{value} < \alpha$  dengan  $n$  adalah banyaknya observasi,  $k$  adalah lag ke- $k$ ,  $K$  merupakan lag maksimum,  $p$  dan  $q$  adalah order dari AR dan MA dan  $\hat{\rho}_k$  adalah autokorelasi residual untuk lag ke- $k$ .

Pengujian kenormalan dapat dihitung dengan menggunakan Kolmogorov-Smirnov dengan hipotesis sebagai berikut (Daniel, 2000: 343-345).

$H_0$  :  $F(a_t) = F_0(a_t)$  (residual berdistribusi normal)

$H_1$  :  $F(a_t) \neq F_0(a_t)$  (residual tidak berdistribusi normal)

Statistik uji yang digunakan adalah.

$$D = \sup |F(a_t) - F_0(a_t)| \quad (2.15)$$

dengan:

$F(a_t)$  : fungsi distribusi kumulatif residual

$F_0(a_t)$  : fungsi distribusi kumulatif distribusi normal

$\sup$  : nilai maksimum dari  $F(a_t) - F_0(a_t)$

Keputusan tolak  $H_0$  apabila  $D > D_{(1-\alpha),n}$  dengan  $n$  adalah banyaknya observasi

#### 2.2.4 Peramalan

Peramalan dilakukan dengan menggunakan model yang didapatkan setelah parameter telah signifikan dan asumsi residual telah dipenuhi. Terdapat dua macam peramalan yaitu peramalan titik dan peramalan interval. Persamaan untuk menghitung taksiran ramalan titik pada waktu  $n+l$  adalah sebagai berikut (Wei, 2006 : 89-90):

$$\hat{Y}_{n+l} = \hat{Y}_n(l) \quad (2.16)$$

dengan  $\hat{Y}_n(l)$  adalah ramalan  $l$  periode kedepan dari  $Y_{n+l}$ . Ramalan interval tahap ke depan adalah sebagai berikut:

$$\hat{Y}_n(l) \pm Z_{\alpha/2} \sqrt{\text{var}(\varepsilon_n(l))} \quad (2.17)$$

dengan  $\varepsilon_n(l)$  adalah kesalahan ramalan pada  $l$  tahap ke depan  $Z_{\alpha/2}$  adalah nilai normal standar. .

## 2.3 ARIMAX

Model ARIMAX adalah modifikasi dari model dasar ARIMA *seasonal* dengan penambahan variabel prediktor. Efek kalender variasi merupakan salah satu variabel prediktor yang seringkali digunakan dalam pemodelan tersebut. Secara umum, jika  $Y_t$  adalah suatu *time series* dengan efek kalender variasi, maka model ARIMAX ditulis sebagai berikut.

$$Y_t = \beta_1 V_{1,t} + \beta_2 V_{2,t} + \dots + \beta_p V_{p,t} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} a_t \quad (2.18)$$

Pada penelitian ini variabel prediktor yang digudakan dalam permodelan ARIMAX adalah variabel dummy musiman harian dan variasi kalender. Sehingga model umum ARIMAX yang terbentuk untuk data beban listrik dengan data per setengah jam ditampilkan sebagai berikut:

$$Y_t = \alpha_1 t + \sum_{i=1}^7 \delta_i D_{i,t}^W + \sum_{j=1}^s \zeta_j D_{i,t}^V + N_t \quad (2.19)$$

$$\text{dengan } N_t = \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} a_t.$$

Keterangan:

$D_{1,t}^W, D_{2,t}^W, \dots, D_{7,t}^W$  : Variabel dummy musiman harian,

$D_{1,t}^V, D_{2,t}^V, \dots, D_{s,t}^V$  : Variabel dummy kalender variasi.

### 2.3.1 Estimasi Parameter

Setelah dilakukan identifikasi, diperoleh model ARIMAX seperti persamaan berikut (Wei, 2006: 332-333):

$$Y_t = \frac{\zeta(B)}{\delta(B)} X_{t-b} + \frac{\theta(B)}{\phi(B)} a_t \quad (2.20)$$

Kemudian dilakukan estimasi parameter  $\delta = (\delta_1, \dots, \delta_r)'$ ,  $\zeta = (\zeta_1, \dots, \zeta_s)'$ ,  $\phi = (\phi_1, \dots, \phi_p)'$ ,  $\theta = (\theta_1, \dots, \theta_q)'$ , dan  $\sigma_a^2$ . Sehingga persamaan pada 2.19 dapat ditulis sebagai berikut:

$$\delta(B)\phi(B)Y_t = \phi(B)\zeta(B)X_{t-b} + \delta(B)\theta(B)a_t, \quad (2.21)$$

atau, sama dengan

$$c(B)Y_t = d(B)X_{t-b} + e(B)a_t, \quad (2.22)$$

dengan,

$$\begin{aligned} c(B) &= \delta(B)\phi(B) = (1 - \delta_1 B - \dots - \delta_r B^r)(1 - \phi_1 B - \dots - \phi_p B^p) \\ &= (1 - c_1 B - c_2 B^2 - \dots - c_{p+r} B^{p+r}) \\ d(B) &= \phi(B)\zeta(B) = (1 - \phi_1 B - \dots - \phi_p B^p)(1 - \zeta_1 B - \dots - \zeta_s B^s) \\ &= (d_0 - d_1 B - d_2 B^2 - \dots - d_{p+s} B^{p+s}) \\ e(B) &= \delta(B)\theta(B) = (1 - \delta_1 B - \dots - \delta_r B^r)(1 - \theta_1 B - \dots - \theta_q B^q) \\ &= (1 - e_1 B - e_2 B^2 - \dots - e_{r+q} B^{r+q}) \end{aligned}$$

Maka,

$$\begin{aligned} a_t &= Y_t - c_1 Y_{t-1} - \dots - c_{p+r} Y_{t-p-r} - d_0 X_{t-b} - d_1 X_{t-b-1} - \dots - \\ &\quad d_{p+s} X_{t-b-p-s} + e_1 a_{t-1} + \dots + e_{r+q} a_{t-r-q} \end{aligned} \quad (2.23)$$

dengan  $c_i$ ,  $d_j$ ,  $e_k$  adalah fungsi dari  $\delta_i$ ,  $\zeta_j$ ,  $\phi_k$ , dan  $\theta_l$ . Dengan asumsi bahwa  $a_t$  deret *white noise*  $N(0, \sigma_a^2)$ , sehingga *conditional likelihood* sebagai berikut:

$$L(\delta, \zeta, \phi, \theta, \sigma_a^2 | b, X, Y, X_0, Y_0, a_0) = (2\pi\sigma_a^2)^{-n/2} \exp \left[ -\frac{1}{2\sigma_a^2} \sum_{t=1}^n a_t^2 \right] \quad (2.24)$$

dengan  $X_0, Y_0, a_0$  adalah nilai-nilai yang sesuai untuk menghitung  $a_t$  pada persamaan (2.23). Secara umum, metode estimasi juga bisa digunakan untuk mengestimasi parameter  $\zeta$ ,  $\delta$ ,  $\phi$ ,  $\theta$ , dan  $\sigma_a^2$ . Sebagai contoh, dengan mengatur nilai  $a$  yang tidak diketahui sama dengan nilai ekspektasi kondisional yaitu 0, estimasi kuadrat terkecil

(*least square*) nonlinier dari parameter tersebut diperoleh dengan meminimumkan

$$S(\delta, \zeta, \phi, \theta | b) = \sum_{t=1}^n a_t^2 \quad (2.25)$$

dengan  $t_0 = \max\{p + r + 1, b + p + s + 1\}$ .

Sejauh ini diasumsikan bahwa  $b$  tidak diketahui. Nilai yang diberikan untuk  $r, s, p$ , dan  $q$ , jika penduga dari  $b$  juga dibutuhkan maka persamaan (2.23) bisa dioptimasi untuk nilai-nilai dari  $b$ . Nilai  $b$  yang dipilih adalah nilai yang memberikan jumlah kuadrat minimum.

## 2.4 Pengujian Linearitas

Salah satu cara untuk menguji linear atau tidaknya suatu data dapat digunakan dengan uji White. Uji White adalah uji deteksi non-linearitas yang dikembangkan dari model neural network yang ditemukan oleh White pada tahun 1989. Persamaan model yang digunakan pada Uji White ditampilkan pada persamaan berikut:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \theta_1 X_{1t}^* + \theta_2 X_{2t}^* + a_t \quad (2.26)$$

dengan  $X_{1t}^*$  dan  $X_{2t}^*$  adalah komponen nonlinear pada White yang diturunkan dari model neural network. Uji White memiliki hipotesis berikut:

$$H_0 : \theta_1 = \theta_2 = \dots = \theta_q = 0 \quad (\text{Hubungan linear})$$

$$H_1 : \text{minimal ada satu } \theta_q \neq 0 \quad (\text{Hubungan tidak linear})$$

Berikut merupakan langkah-langkah dari pengujian White:

1. Meregresikan  $Y_t$  pada  $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$  dan menghitung *residual*

$$\hat{u}_t \text{ dan menghitung } \text{sum square residual } SSR_0 = \sum_{t=1}^n \hat{u}_t^2.$$

2. Meregresikan  $\hat{u}_t$  pada  $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$  dan 2 prediktor tambahan

$$\text{dan menghitung } \text{residual } \hat{v}_t \text{ dan } \text{sum square residual } SSR_1 = \sum_{t=1}^n \hat{v}_t^2$$

3. Menghitung  $F_{hitung} = \frac{(SSR_0 - SSR_1) / 2}{SSR_1 / (n - p - 1 - 2)}$ ,

dengan  $n$  adalah jumlah pengamatan yang digunakan.

Di bawah hipotesis linearitas, nilai uji  $F$  ini mendekati distribusi  $F$  dengan derajat bebas 2 dan  $(n - p - 1 - 2)$ .

## 2.5 Neural Network

*Neural Network* merupakan salah satu metode yang dapat digunakan untuk data yang *nonlinear*. NN dikarakteristikan dengan pola koneksi antar neuron (arsitektur), metode menentukan bobot pada koneksi (*training/learning/algoritma*), dan fungsi aktivasi. NN terdiri dari elemen-elemen untuk pemrosesan informasi yang disebut dengan neuron, unit, dan sel atau node (Fausett, 1994: 3). Bentuk arsitektur NN yang sering digunakan adalah *Single Hidden Layer Feedforward Neural Network*. Pada FFNN terdiri dari tiga lapisan diantaranya lapisan *input*, lapisan tersembunyi, dan lapisan *output*. Dalam FFNN neuron saling berhubungan antar layer, sehingga aliran data hanya satu arah. Kemudian tiap neuron menerima informasi hanya dari lapisan sebelumnya, *input* dari setiap neuron adalah bobot dari *output* neuron pada lapisan sebelumnya (Chong & Zak, 2001: 220). Berikut merupakan persamaan *output* FFNN dengan satu *hidden layer* dengan  $p$  *input* dan  $q$  unit neuron pada *hidden layer*:

$$\hat{Y} = f^o(b^o + \sum_{j=1}^q w_j^o f_j^1(b_j^1 + (\sum_{i=1}^p w_{ij}^1 Z_{it}))) \quad (2.27)$$

dengan

$\hat{Y}$  : variabel *output*

$f^o$  : fungsi aktivasi pada lapisan *output*

$b^o$  : bias neuron pada lapisan *output*

$w_j^o$  : bobot dari neuron ke- $j$  pada lapisan tersembunyi yang menuju neuron pada lapisan *output*

$f_j^1$  : fungsi aktivasi neuron ke- $j$  pada lapisan tersembunyi ke-1




$b_j^1$  : bias neuron ke-  $j$  pada lapisan tersembunyi ke-1

$w_{ij}^1$  : bobot *input* ke-  $i$  yang menuju ke neuron ke- $j$  pada lapisan tersembunyi ke-1

$Z_{it}$  : variabel *input*.

Berikut merupakan bentuk struktur FFNN dengan satu *hidden layer* dengan  $q$  *input* dan  $p$  unit neuron pada *hidden layer*:



**Gambar 2.1** Struktur FFNN Satu *Hidden Layer*

Untuk mendapatkan persamaan umum untuk struktur FFNN, misalnya  $v_j$  notasi untuk penjumlahan *input* dan bobot pada lapisan tersembunyi di neuron ke- $j$  dan  $a_j$  notasi untuk *output* pada lapisan tersembunyi di neuron ke- $j$  sehingga

$$v_j^1 = b_j^1 + \sum_{i=1}^p w_{ij}^1 Z_i \quad (2.28)$$

$$a_j^1 = f_j^1(v_j^1) = f_j^1(b_j^1 + \sum_{i=1}^p w_{ij}^1 Z_i) . \quad (2.29)$$

Selanjutnya penjumlahan *input* dan bobot pada lapisan *output* didapatkan

$$v^o = b^o + \sum_{j=1}^q w_j^o a_j^1 \quad (2.30)$$

$$\hat{Y} = a^o = f^o(v^o) = f^o(b^o + \sum_{j=1}^q w_j^o a_j^1) . \quad (2.31)$$

Sehingga, hubungan antara *input*  $z_i$ ,  $i=1, 2, \dots, p$  dan  $k = 1, 2, \dots, r$  untuk *output*  $\hat{Y}$  adalah

$$\begin{aligned} \hat{Y} &= f^o(b^o + \sum_{j=1}^q w_j^o a_j^1) \\ &= f^o(b^o + \sum_{j=1}^q w_j^o f_j^1(b_j^1 + (\sum_{i=1}^p w_{ij}^1 Z_i))) \\ &= F(z_1, z_2, \dots, z_p) \end{aligned} \quad (2.32)$$

Secara keseluruhan pemetaan untuk implementasi FFNN adalah

$$\begin{bmatrix} \hat{Y}_1 \\ \hat{Y}_2 \\ \vdots \\ \hat{Y}_n \end{bmatrix} = \begin{bmatrix} F_1(Z_1, Z_2, \dots, Z_n) \\ F_2(Z_1, Z_2, \dots, Z_n) \\ \vdots \\ F_n(Z_1, Z_1, \dots, Z_n) \end{bmatrix}. \quad (2.33)$$

## 2.6 Algoritma *Backpropagation*

Algoritma *Backpropagation* adalah algoritma yang dapat digunakan untuk melatih NN. Melatih NN dengan *backpropagation* terdiri dari tiga tahap yaitu *feedforward* dari *input* pola pelatihan, menghitung *backpropagation* dari error, dan menentukan bobot. Faktor terpenting dalam menentukan kelakuan suatu neuron adalah fungsi aktivasi dan pola bobotnya. Fungsi aktivasi adalah fungsi untuk menentukan nilai keluaran berdasarkan nilai total masukan pada neuron. Syarat fungsi aktivasi untuk *backpropagation* diantaranya kontinu, mudah diturunkan, dan merupakan fungsi yang tidak turun. Terdapat berbagai macam jenis fungsi aktivasi yang dapat digunakan diantaranya fungsi Linear, fungsi Sigmoid Biner, fungsi Sigmoid Bipolar, dan Hyperbolic Tangent. Fungsi Linear memiliki nilai output yang

sama dengan nilai inputnya. Fungsi ini dapat dirumuskan sebagai berikut (Fausett, 1994:17-19):

$$f(x) = x \quad (2.34)$$

Pada fungsi Sigmoid Biner sering digunakan untuk NN yang dilatih dengan menggunakan metode *Backpropagation*. Fungsi sigmoid biner memiliki nilai pada *range* 0 sampai 1. Fungsi sigmoid biner dirumuskan sebagai berikut:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.35)$$

Fungsi sigmoid bipolar hampir sama dengan fungsi sigmoid biner, hanya output dari fungsi ini memiliki range antara 1 sampai -1. Fungsi sigmoid bipolar dirumuskan sebagai berikut :

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (2.36)$$

Untuk fungsi *Hyperbolic Tangent* memiliki range yang sama seperti fungsi sigmoid bipolar yaitu memiliki range antara -1 sampai 1. Berikut merupakan fungsi *Hyperbolic Tangent*:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.37)$$

Dalam menentukan bobot dalam NN misalnya diberikan *input*  $Z_d = [Z_{d1}, \dots, Z_{dp}]^T$ . Untuk menentukan bobot dapat digunakan formula seperti berikut:

$$\min \frac{1}{2} \sum_{t=1}^r (Z_{dt} - \hat{Y})^2 \quad (2.38)$$

dengan  $\hat{Y}$ ,  $t = 1, 2, \dots, r$  adalah nilai *output* sebenarnya dari NN dengan

$$\hat{Y} = f^o \left( b^o + \sum_{j=1}^q w_j^o f_j^1 (b_j^1 + (\sum_{i=1}^p w_{ij}^1 Z_i)) \right) \quad (2.39)$$

Pada persamaan (2.39) digunakan untuk mendapatkan nilai bobot  $w_{ij}^1, w_j^o$ . Untuk menyederhanakan notasi, digunakan simbol  $\mathbf{w}$  untuk vektor

$$\mathbf{w} = \{w_{ij}^1, w_j^o; i = 1, 2, \dots, p, j = 1, 2, \dots, q\} \quad (2.40)$$

dan simbol  $E$  untuk fungsi objektif yang akan diminimalkan dapat ditulis

$$\begin{aligned} E(\mathbf{w}) &= \frac{1}{2} \sum_{t=1}^r (Z_{dt} - \hat{Y})^2 \\ &= \frac{1}{2} \sum_{t=1}^r (Z_{dt} - f^o(b^o + \sum_{j=1}^q w_j^o f_j^1(b_j^1 + (\sum_{i=1}^p w_{ij}^1 Z_i))))^2 \end{aligned} \quad (2.41)$$

Dalam menyelesaikan masalah optimasi, digunakan algoritma gradient dengan persamaan berikut.

$$\Delta \mathbf{w} = -\eta \frac{\partial E(\mathbf{w})}{\partial \mathbf{w}} \text{ atau } \mathbf{w}^{(m+1)} = \mathbf{w}^{(m)} - \eta \frac{\partial E(\mathbf{w})^{(m)}}{\partial \mathbf{w}} \quad (2.42)$$

Untuk memformulasikan algoritma tersebut, akan dilakukan penurunan parsial dari  $E(\mathbf{w})$  terhadap masing-masing komponen  $\mathbf{w}$ . Pertama, menghitung turunan parsial dari  $E$  terhadap  $w_j^o$  yaitu,

$$E(\mathbf{w}) = \frac{1}{2} \sum_{t=1}^r (Z_{dt} - f^o(b^o + \sum_{j=1}^q w_j^o a_j^1))^2 \quad (2.43)$$

dengan  $j = 1, 2, \dots, q$ . Dengan menggunakan aturan rantai untuk perhitungan turunan parsial yaitu

$$\frac{\partial E(\mathbf{w})}{\partial w_j^o} = \frac{\partial E(\mathbf{w})}{\partial a_j^1} \frac{\partial a_j^1}{\partial v_j^1} \frac{\partial v_j^1}{\partial w_j^o} \quad (2.44)$$

didapatkan

$$\frac{\partial E(\mathbf{w})}{\partial w_j^o} = -\sum_{t=1}^r (Z_{dt} - f^o(b^o + \sum_{j=1}^q w_j^o a_j^1)) f^{o'}(b^o + \sum_{j=1}^q w_j^o a_j^1) a_j^1 \quad (2.45)$$

dengan  $f^{o'}$  adalah turunan dari  $f^o$ . Untuk menyederhanakan notasi, dapat ditulis

$$\delta_t^o = (Z_{dt} - \hat{Y})f^{o'}(b^o + \sum_{j=1}^q w_j^o a_j^1) \quad (2.46)$$

sehingga didapatkan

$$\frac{\partial E(\mathbf{w})}{\partial w_j^o} = -\sum_{t=1}^r \delta_t^o a_j^1. \quad (2.47)$$

Selanjutnya, menghitung turunan parsial dari  $E(\mathbf{w})$  terhadap  $w_{ij}^1$  dengan menggunakan aturan rantai sebagai berikut:

$$\frac{\partial E(\mathbf{w})}{\partial w_{ij}^1} = \frac{\partial E(\mathbf{w})}{\partial a^o} \frac{\partial a^o}{\partial v^o} \frac{\partial v^o}{\partial a_j^1} \frac{\partial a_j^1}{\partial v_j^1} \frac{\partial v_j^1}{\partial w_{ij}^1} \quad (2.48)$$

didapatkan

$$\frac{\partial E(\mathbf{w})}{\partial w_{ij}^1} = -\sum_{t=1}^r (Z_{dt} - \hat{Y})f^{o'}(b^o + \sum_{j=1}^q w_j^o a_j^1)w_j^o f_j^{1'}(b_j^1 + \sum_{i=1}^p w_{ij}^1 Z_i)Z_i \quad (2.49)$$

dengan  $f^{1'}$  adalah turunan dari  $f^1$ . Untuk menyederhanakan notasi, dapat ditulis

$$\frac{\partial E(\mathbf{w})}{\partial w_{ij}^1} = -\sum_{t=1}^r (\delta^o w_j^o)(f_j^{1'}(b_j^1 + \sum_{i=1}^p w_{ij}^1 Z_i))Z_i \quad (2.50)$$

atau

$$\frac{\partial E(\mathbf{w})}{\partial w_{ij}^1} = -\sum_{t=1}^r \delta_j^1 Z_i \text{ dengan } \delta_j^1 = \delta_t^o w_j^o (f_j^{1'}(v_j^1)). \quad (2.51)$$

Dengan cara yang sama, dilakukan penurunan parsial dari  $E(\mathbf{w})$  terhadap  $b^o, b_j^1$  dengan menggunakan aturan rantai. Sehingga didapatkan

$$\frac{\partial E(\mathbf{w})}{\partial b^o} = -\sum_{t=1}^r \delta_t^o \quad (2.52)$$

$$\frac{\partial E(\mathbf{w})}{\partial b_j^1} = -\sum_{k=1}^r \delta_j^1. \quad (2.53)$$

Selanjutnya memformulasikan algoritma *gradient* untuk mengupdate bobot dari NN, sehingga diperoleh:

a. Untuk mengupdate bobot dan bias pada lapisan *output*

$$w_j^{o(m+1)} = w_j^{o(m)} + \eta \sum_{t=1}^r \delta_t^{o(m)} a_j^{1(m)} \quad (2.54)$$

$$b^{o(m+1)} = b^{o(m)} + \eta \sum_{t=1}^r \delta_t^{o(m)}. \quad (2.55)$$

b. Untuk mengupdate bobot dan bias pada lapisan tersembunyi

$$w_{ij}^{1(m+1)} = w_{ij}^{1(m)} + \eta \sum_{t=1}^r \delta_j^{1(m)} Z_i^{(m)} \quad (2.56)$$

$$b_j^{1(m+1)} = b_j^{1(m)} + \eta \sum_{t=1}^r \delta_j^{1(m)} \quad (2.57)$$

dengan  $\eta$  koefisien pembelajaran yang ditentukan,  $0 < \eta < 1$ .


## 2.7 Deep Neural Network

*Deep Learning* merupakan cabang ilmu dari *machine learning* berbasis *artificial Neural Network*. Sedangkan *Deep Learning* memiliki struktur yang sama dengan NN namun yang membedakan adalah terdapat lebih dari satu hidden layer pada *Deep Learning*. Saat ini *Deep Learning* dapat digunakan untuk *computer vision*, *text processing*, *translation*, dan prediksi *time series*. *Deep Neural Network* terdiri dari lapisan input, lapisan keluaran, dan sejumlah lapisan tersembunyi. Hal ini menyerupai dengan multi-layer perceptron (MLP) tetapi dengan banyak lapisan tersembunyi dan banyak neuron yang terhubung per lapisan. Terdapatnya beberapa lapisan tersembunyi pada DNN mempunyai kelebihan dapat mendekati fungsi keputusan yang sangat kompleks (Lewis, 2016). Berikut merupakan bentuk struktur *Deep Neural Network* dengan dua *hidden layer*. Berikut merupakan persamaan dari output  $\hat{Y}$  :

$$\hat{Y} = f^o \left( b^o + \sum_{k=1}^r w_k^o f_k^2 (b_k^2 + \sum_{j=1}^q w_{jk}^2 f_j^1 (b_j^1 + \sum_{i=1}^p w_{ij}^1 Z_{it})) \right) \quad (2.58)$$

dengan

- $\hat{Y}$  : variabel *output*  
 $f^o$  : fungsi aktivasi pada lapisan *output*  
 $b^o$  : bias neuron pada lapisan *output*  
 $w_k^o$  : bobot dari neuron ke-  $k$  pada lapisan tersembunyi yang menuju neuron pada lapisan *output*  
 $f_k^2$  : fungsi aktivasi neuron ke-  $j$  pada lapisan tersembunyi ke-2  
 $b_k^2$  : bias neuron ke-  $k$  pada lapisan tersembunyi ke-2  
 $w_{jk}^2$  : bobot *input* ke-  $j$  yang menuju ke neuron ke- $k$  pada lapisan tersembunyi ke-2  
 $f_j^1$  : fungsi aktivasi neuron ke-  $j$  pada lapisan tersembunyi ke-1  
 $b_j^1$  : bias neuron ke-  $j$  pada lapisan tersembunyi ke-1  
 $w_{ij}^1$  : bobot *input* ke-  $i$  yang menuju ke neuron ke- $j$  pada lapisan tersembunyi ke-1  
 $Z_{it}$  : variabel *input*.



**Gambar 2.2** Struktur *Deep Neural Network*

Untuk mendapatkan persamaan umum untuk struktur DNN, misalnya  $v_j$  notasi untuk penjumlahan *input* dan bobot pada lapisan tersembunyi di neuron ke- $j$  dan  $a_j$  notasi untuk *output* pada lapisan tersembunyi di neuron ke- $j$  sehingga

$$v_j^1 = b_j^1 + \sum_{i=1}^p w_{ji}^1 Z_i \quad (2.59)$$

$$a_j^1 = f_j^1(v_j^1) = f_j^1(b_j^1 + \sum_{i=1}^p w_{ji}^1 Z_i) \quad (2.60)$$

Selanjutnya  $v_k$  notasi untuk penjumlahan *input* dan bobot pada lapisan tersembunyi di neuron ke- $k$  dan  $a_k$  notasi untuk *output* pada lapisan tersembunyi di neuron ke- $k$  sehingga

$$v_k^2 = b_k^2 + \sum_{j=1}^q w_{jk}^2 a_j^1 \quad (2.61)$$

$$a_k^2 = f_k^2(v_k^2) = f_k^2(b_k^2 + \sum_{j=1}^q w_{jk}^2 a_j^1). \quad (2.62)$$

Selanjutnya penjumlahan *input* dan bobot pada lapisan *output* didapatkan

$$v^o = b^o + \sum_{k=1}^r w_k^o a_k^2 \quad (2.63)$$

$$\hat{Y} = a^o = f^o(v^o) = f^o(b^o + \sum_{k=1}^r w_k^o a_k^2). \quad (2.64)$$

Sehingga, hubungan antara *input*  $z_i$ ,  $i=1, 2, \dots, p$  dan  $l=1, 2, \dots, s$  untuk *output*  $\hat{Y}$  adalah

$$\begin{aligned} \hat{Y} &= f^o(b^o + \sum_{k=1}^r w_k^o a_k^2) \\ &= f^o(b^o + \sum_{k=1}^r w_k^o f_k^2(b_k^2 + \sum_{j=1}^q w_{jk}^2 f_j^1(b_j^1 + \sum_{i=1}^p w_{ji}^1 Z_i))) \quad (2.65) \\ &= \mathbf{F}(z_1, z_2, \dots, z_p) \end{aligned}$$



Secara keseluruhan pemetaan untuk implementasi DNN adalah

$$\begin{bmatrix} \hat{Y}_1 \\ \hat{Y}_2 \\ \vdots \\ \hat{Y}_s \end{bmatrix} = \begin{bmatrix} F_1(Z_1, Z_2, \dots, Z_s) \\ F_2(Z_1, Z_2, \dots, Z_s) \\ \vdots \\ F_s(Z_1, Z_2, \dots, Z_s) \end{bmatrix}. \quad (2.66)$$

Selanjutnya dengan cara yang sama seperti *backpropagation* pada NN, diperoleh formulasi algoritma *gradient* untuk mengupdate bobot dari DNN sebagai berikut:

a. Untuk mengupdate bobot dan bias pada lapisan *output*

$$w_k^{o(m+1)} = w_k^{o(m)} + \eta \sum_{t=1}^s \delta_t^{o(m)} a_k^{2(m)} \quad (2.67)$$

$$b^{o(m+1)} = b^{o(m)} + \eta \sum_{t=1}^s \delta_t^{o(m)} \quad (2.68)$$

dengan

$$\delta_t^o = (Z_{dt} - \hat{Z}_t) f^{o'}(b^o + \sum_{k=1}^r w_k^o a_k^2). \quad (2.69)$$

b. Untuk mengupdate bobot dan bias pada lapisan tersembunyi ke-2

$$w_{jk}^{2(m+1)} = w_{jk}^{2(m)} + \eta \sum_{t=1}^s \delta_k^{2(m)} a_j^{1(m)} \quad (2.70)$$

$$b_k^{2(m+1)} = b_k^{2(m)} + \eta \sum_{k=1}^r \delta_k^{2(m)} \quad (2.71)$$

dengan

$$\delta_k^2 = \delta_t^o w_k^o f^{1'}(b_k^2 + \sum_{j=1}^q w_{jk}^2 a_j^1). \quad (2.72)$$

c. Untuk mengupdate bobot dan bias pada lapisan tersembunyi ke-1

$$w_{ij}^{1(m+1)} = w_{ij}^{1(m)} + \eta \sum_{t=1}^s \delta_j^{1(m)} Z_i^{(m)} \quad (2.73)$$

$$b_j^{1(m+1)} = b_j^{1(m)} + \eta \sum_{k=1}^r \delta_j^{1(m)} \quad (2.74)$$

dengan

$$\delta_j^1 = \delta_i^o \delta_k^2 w_{jk}^2 f^{1'}(b_j^1 + \sum_{i=1}^p w_{ij}^1 Z_i) \quad (2.75)$$

dengan  $\eta$  koefisien pembelajaran yang ditentukan,  $0 < \eta < 1$ .

## 2.8 Model Hibrida

Model hibrida adalah model yang menggabungkan antara komponen model linear dan model non linear. Permodelan menggunakan hibrida bertujuan untuk meningkatkan keakurasian dari sebuah peramalan. Secara umum model hibrida dapat ditulis sebagai berikut (Zhang, 2003):

$$Y_t = L_t + N_t + a_t \quad (2.76)$$

atau

$$\hat{Y}_t = \hat{L}_t + \hat{N}_t \quad (2.77)$$

dengan  $L_t$  merupakan komponen linear dan  $N_t$  merupakan komponen non linear. Kedua komponen ini diestimasi berdasarkan data. Tahap pertama memodelkan data pada level pertama menggunakan model linear yaitu model ARIMAX dengan persamaan (2.18) dan didapatkan *residual*  $e_t$  yang merupakan *error* pada waktu ke- $t$ . Berikut merupakan persamaan dari *residual*  $e_t$ :

$$e_t = Y_t - \hat{L}_t^{(1)} \quad (2.78)$$

dengan  $\hat{L}_t^{(1)}$  merupakan nilai *forecast* untuk waktu ke- $t$  dari model linear. Tahap selanjutnya adalah memodelkan *error* dari model linear dengan model non linear yaitu model *Deep Neural Network* dengan persamaan (2.58). Sehingga didapatkan model nonlinear seperti berikut:

$$e_t = \hat{N}_t^{(2)} - a_t \quad (2.79)$$

Sehingga didapatkan model peramalan keseluruhan seperti berikut:

$$\hat{Y}_t = \hat{L}_t^{(1)} + \hat{N}_t^{(2)} . \quad (2.80)$$

## 2.9 Pemilihan Model Terbaik

Pemilihan model terbaik pada penelitian ini menggunakan kriteria kesalahan peramalan untuk *out sample* yaitu *Root Mean Square Error Prediction* (RMSEP) dan *Symmetric Mean Absolute Percentage Error Prediction* (sMAPEP). Rumus RMSE adalah sebagai berikut:

$$RMSEP = \sqrt{\frac{1}{L} \sum_{l=1}^L (Y_{n+l} - \hat{Y}_n(l))^2} . \quad (2.81)$$

Rumus sMAPEP adalah sebagai berikut (Gooijer & Hyndman, 2006):

$$sMAPEP = \frac{1}{L} \sum_{l=1}^L \frac{|Y_{n+l} - \hat{Y}_n(l)|}{(|Y_{n+l}| + |\hat{Y}_n(l)|) / 2} \times 100\% \quad (2.82)$$

dengan

$Z_{n+l}$  : data *out sample*

$Z_{n(l)}$  : nilai ramalan

$L$  : jumlah data *out sample*


RMSEP dan MSEP merupakan kriteria pemilihan model yang populer namun RMSEP lebih disukai daripada MSEP. Penggunaan RMSEP apabila jika series data memiliki skala yang sama (Hyndman & Koehler, 2006). Selain itu, RMSEP dan MSEP lebih sensitif terhadap *outliers* daripada MAEP atau MdAEP. Sedangkan sMAPEP digunakan untuk mengatasi nilai  $Z_{n+l}$ , yang mendekati nilai nol. Penggunaan sMAPEP dapat mengatasi masalah error yang besar (Makridakis & Hibon, 2000). Misalnya:

**Tabel 2.2** Perbandingan MAPEP dan sMAPEP

$Z_{n+l}$	$\hat{Z}_n(l)$	$a_t$	MAPEP	sMAPEP
100	50	-50	50%	66,67%
50	100	50	100%	66,67%

## 2.10 Peramalan Beban Listrik

Tenaga listrik dibangkitkan oleh suatu pusat pembangkit listrik, selanjutnya tenaga listrik disalurkan (ditransmisikan) melalui jaringan transmisi. Dari jaringan transmisi selanjutnya didistribusikan kepada para konsumen tenaga listrik melalui jaringan distribusi tenaga listrik (Muslim, Joko, & Wanarti, 2008). Berikut merupakan proses listrik disalurkan:



**Gambar 2. 3** Proses Listrik Disalurkan

Beban atau yang sering disebut sebagai *demand*, merupakan besaran kebutuhan tenaga listrik yang dinyatakan dengan MWh, MW atau MVA tergantung dengan konteksnya (ESDM, 2016). Berdasarkan jenis konsumen energi listrik, jenis beban dapat diklasifikasikan sebagai berikut (Suswanto, 2009).

### 1. Beban rumah tangga

Pada umumnya beban rumah tangga berupa lampu untuk penerangan, alat rumah tangga, seperti kipas angin, pemanas air, lemari es, penyejuk udara, *mixer*, oven, motor pompa air dan sebagainya. Beban rumah tangga biasanya memuncak pada malam hari.

### 2. Beban komersial

Pada umumnya terdiri atas penerangan untuk reklame, kipas angin, penyejuk udara dan alat – alat listrik lainnya yang diperlukan untuk restoran. Beban hotel juga diklasifikasikan

sebagai beban komersial (bisnis) begitu juga perkantoran. Beban ini secara drastis naik di siang hari untuk beban perkantoran dan pertokoan dan menurun di waktu sore.

3. Beban industri

Beban Industri dibedakan dalam skala kecil dan skala besar. Untuk skala kecil banyak beroperasi di siang hari sedangkan industri besar sekarang ini banyak yang beroperasi sampai 24 jam.

4. Beban Fasilitas Umum.

Peramalan beban listrik sangat penting dalam perencanaan operasi. Dengan adanya analisis peramalan beban listrik ini akan membantu pihak PLN mengambil kebijakan misalnya dalam hal menyuplai tenaga listrik, mengatur pembangkitan. Menurut jangka waktunya, peramalan beban listrik dapat dikelompokkan menjadi sebagai berikut:

1. Peramalan Jangka Panjang (*Long Term Forecasting*)

Merupakan peramalan yang memperkirakan keadaan dalam waktu beberapa tahun ke depan. Tujuannya adalah untuk mempersiapkan ketersediaan unit pembangkitan, sistem transmisi, serta distribusi.

2. Peramalan Jangka Medium (*Mid Term Forecasting*)

Merupakan peramalan dalam waktu bulanan atau mingguan. Tujuannya untuk mempersiapkan jadwal persiapan dan operasional sistem pembangkit.

3. Peramalan Jangka Pendek (*Short Term Forecasting*)

Merupakan peramalan jangka waktu harian hingga setiap jam. Biasa digunakan untuk studi perbandingan beban listrik perkiraan dan aktual.

## 2.11 Penelitian Sebelumnya

**Tabel 2.3** Rangkuman Penelitian Sebelumnya

<b>Judul dan Peneliti</b>	<b>Model yang Digunakan</b>	<b>Studi Kasus</b>	<b>Hasil</b>
<i>Enhancing Electric Load Forecasting of ARIMA and ANN Using Adaptive Fourier Series</i> ; Eljazzar dan Hemayed (2017)	ARIMA dan ANN dengan <i>Adaptive Fourier Series</i>	Peramalan Listrik per Jam pada data The Electric Reliability Council of Texas (ERCOT)	ANN yang ditingkatkan dengan menambahkan koefisien pada deret Fourier lebih baik dibandingkan model ARIMA
<i>Hybrid Short Term Load Forecasting using ARIMA-SVM</i> ; Karthika dkk. (2017)	Hibrida ARIMA-SVM, ARIMA, SVM	Peramalan listrik jangka pendek dari data sistem utilitas wilayah selatan dengan adanya faktor eksternal seperti termperatur, hari dll.	ARIMA-SVM akan menghasilkan performa yang lebih baik \
<i>Load Forecasting via Deep Neural Networks</i> ; He (2017)	Linear regresi, SVR, DNN, CNN dan RNN, dan Paralel CNN dan RNN	Peramalan listrik per jam di wilayah China Utara	Paralel CNN dan RNN mampu mengurangi hampir 5% dari MAPE dan MAE

**Tabel 2.3** Rangkuman Penelitian Sebelumnya (lanjutan)

<b>Judul dan Peneliti</b>	<b>Model yang Digunakan</b>	<b>Studi Kasus</b>	<b>Hasil</b>
<i>Using The Multiplicative Double Seasonal Holt-Winters Method To Forecast Short-Term Electricity Demand</i> ; Franse (2017)	SARIMA dan tiga kombinasi model Holt-Winter.	Peramalan beban listrik jangka pendek untuk kasus di Wales dan Inggris.	<i>Double seasonal</i> Holt-Winter dengan pengaturan AR lebih baik dibandingkan dengan model lain
<i>Modeling and forecasting short-term electricity load: A comparison of methods with an application to Brazilian data</i> ; Soares dan Medeiros (2008)	TLSAR, DASARIMA, <i>Generalized Linear Model</i> , dan NN	Peramalan beban listrik per jam pada wilayah Brazil Tenggara	Secara umum, model TLSAR merupakan model terbaik untuk peramalan pada penelitian ini. Namun, beberapa model baik untuk waktu tertentu misalnya DASARIMA baik untuk meramalkan untuk jam 01:00-05:00 dan NN untuk jam 07:00-18:00.

**Tabel 2.3** Rangkuman Penelitian Sebelumnya (lanjutan)

<b>Judul dan Peneliti</b>	<b>Model yang Digunakan</b>	<b>Studi Kasus</b>	<b>Hasil</b>
Short Term Power Load Forecasting Using Deep Neural Networks; Din dan Marnerides (2017)	FFDNN dan RDNN	Peramalan beban listrik per jam pada New England, USA periode 2007 sampai 2017 dengan mempertimbangkan suhu hari faktor eksternal lain	RDNN lebih baik dibandingkan dengan FFDNN
Weather Forecasting using Deep Feed Forward Neural Network (DFFNN) and Fuzzy Outlier Removal; Nagaselvi dan Deepa (2015)	Model FFDNN dan membandingkan dengan model ANN serta menerapkan teknik fuzzy untuk menghapus data <i>outlier</i> yang ada sebagai langkah pada <i>pre-processing data</i> .	Peramalan cuaca periode 21 Desember 2011 hingga 9 Januari 2013 pada Statesboro, Georgia	FFDNN untuk peramalan cuaca menghasilkan akurasi yang lebih tinggi dibandingkan peramalan cuaca dengan ANN



## BAB III METODOLOGI PENELITIAN

Pada penelitian ini akan dilakukan dua kajian analisis yaitu kajian simulasi dan kajian terapan. Pada bab ini akan dibahas mengenai metodologi penelitian yang meliputi sumber data, variabel penelitian dan langkah penelitian serta jadwal penelitian.

### 3.1 Kajian Simulasi

Langkah awal dalam kajian simulasi ini adalah membangkitkan data yang mengandung pola tren, musiman, variasi kalender, dan *noise*. Dalam kajian simulasi ini akan dibentuk dua skenario. Skenario 1 adalah data simulasi yang mengandung komponen tren, musiman, variasi kalender, dan noise linear sedangkan untuk skenario 2 adalah data simulasi yang mengandung komponen tren, musiman, variasi kalender, dan noise nonlinear. Data beban konsumsi listrik per setengah jam wilayah Jateng dan DIY periode Januari 2013 sampai Desember 2017 menjadi acuan dalam membangkitkan data. Data simulasi adalah beban total yang merupakan penjumlahan dari beban potensial dan beban irregular. Pertama, akan dibangkitkan beban potensial yaitu model dengan mengandung komponen tren, musiman harian, variasi kalender, dan *noise* dengan persamaan sebagai berikut:

$$Y_{J,t}^P = T_t + D_t^W + D_t^V \quad (3.1)$$

dengan:

$T_t$  : komponen untuk tren linier,

$D_t^W$  : komponen untuk pola musiman harian,

$D_t^V$  : komponen untuk variasi kalender.

Selanjutnya akan dibangkitkan beban irregular mengikuti pola linear dan pola nonlinear. Untuk pola linear akan mengikuti pola AR(1) sedangkan pola nonlinear akan mengikuti pola ESTAR(1). Berikut merupakan persamaan untuk beban irregular:

$$Y_{J,t}^I = \phi' \mathbf{z}_{J,t} + a_{J,t} \quad (3.2)$$

dengan:

$\phi' \mathbf{z}_{J,t}$  : komponen AR(1) atau ESTAR(1)

$a_{J,y}$  : komponen *noise*.

1. Komponen tren

Kajian simulasi pada penelitian ini akan digunakan komponen tren dengan persamaan sebagai berikut:

$$T_t = 0,3t \quad (3.3)$$

2. Komponen musiman

Pada kajian simulasi ini akan dibangkitkan data yang mengandung komponen musiman harian dengan persamaan sebagai berikut:

$$M_t = \delta_1^1 D_{1,t}^W + \delta_2^1 D_{2,t}^W + \delta_3^1 D_{3,t}^W + \delta_4^1 D_{4,t}^W + \delta_5^1 D_{5,t}^W + \delta_6^1 D_{6,t}^W + \delta_7^1 D_{7,t}^W \quad (3.4)$$

Untuk membangkitkan data komponen musiman harian akan digunakan pembobotan yang mengacu pada data beban listrik jangka pendek per setengah jam. Berikut merupakan pembobotan untuk komponen musiman harian:

**Tabel 3.1** Pembobotan untuk Komponen Musiman Harian

Jam	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
00:30	2496	2627	2631	2630	2639	2633	2577
01:00	2455	2590	2589	2592	2605	2585	2529
01:30	2417	2561	2559	2563	2567	2551	2502
02:00	2390	2526	2528	2530	2537	2516	2468
02:30	2365	2501	2502	2507	2508	2480	2442
03:00	2357	2481	2491	2494	2498	2467	2416
03:30	2366	2490	2489	2497	2503	2473	2422
04:00	2398	2519	2534	2529	2540	2499	2439
04:30	2509	2626	2642	2638	2630	2601	2518
05:00	2634	2753	2773	2755	2750	2724	2616
05:30	2750	2848	2883	2860	2848	2825	2661
06:00	2694	2773	2786	2779	2779	2731	2560
06:30	2555	2640	2654	2633	2627	2573	2457
07:00	2486	2559	2564	2545	2539	2476	2385
07:30	2560	2639	2629	2617	2591	2523	2366
08:00	2661	2714	2713	2702	2679	2578	2366

**Tabel 3.1** Pembobotan untuk Komponen Musiman Harian (lanjutan)

<b>Jam</b>	<b>Senin</b>	<b>Selasa</b>	<b>Rabu</b>	<b>Kamis</b>	<b>Jumat</b>	<b>Sabtu</b>	<b>Minggu</b>
08:30	2769	2811	2818	2801	2775	2669	2397
09:00	2822	2868	2859	2850	2820	2714	2409
09:30	2863	2898	2887	2877	2865	2745	2437
10:00	2893	2924	2913	2896	2897	2780	2457
10:30	2928	2961	2946	2931	2931	2819	2476
11:00	2949	2976	2970	2948	2962	2842	2483
11:30	2947	2976	2960	2953	2907	2844	2484
12:00	2859	2893	2876	2863	2774	2783	2464
12:30	2844	2864	2861	2850	2745	2746	2451
13:00	2916	2952	2941	2914	2874	2761	2454
13:30	3016	3047	3046	3017	2975	2810	2475
14:00	3002	3031	3027	3007	2970	2791	2464
14:30	2981	3009	2992	2984	2949	2753	2455
15:00	2951	2986	2965	2949	2914	2745	2465
15:30	2970	3014	2976	2973	2936	2759	2513
16:00	2974	2999	2965	2962	2937	2776	2558
16:30	2985	2998	2953	2962	2934	2787	2616
17:00	3039	3053	3021	3021	2995	2873	2717
17:30	3256	3259	3239	3239	3224	3111	2967
18:00	3519	3537	3528	3514	3489	3407	3277
18:30	3577	3601	3603	3585	3562	3502	3388
19:00	3579	3614	3610	3583	3577	3499	3397
19:30	3564	3608	3591	3568	3548	3467	3363
20:00	3537	3560	3560	3548	3511	3439	3347
20:30	3490	3510	3507	3504	3467	3383	3296
21:00	3374	3397	3384	3389	3357	3290	3188
21:30	3214	3225	3229	3241	3204	3146	3047
22:00	3046	3065	3075	3091	3053	3004	2901
22:30	2937	2941	2952	2975	2931	2890	2778
23:00	2829	2837	2847	2859	2833	2789	2689
23:30	2756	2763	2769	2778	2761	2712	2617
00:00	2677	2687	2687	2703	2682	2638	2554

### 3. Komponen variasi kalender

Komponen variasi kalender merupakan data yang dibangkitkan dengan adanya pengaruh kejadian-kejadian tertentu misalnya hari libur selain hari Minggu. Daftar tanggal hari libur selain hari minggu tahun 2013 hingga 2017 dapat dilihat pada Tabel 3.2.

### 4. Komponen *noise*

Komponen yang digunakan dalam kajian simulasi ini adalah *noise* yang mengandung pola linear yaitu pola AR(1) untuk skenario 1 dan *noise* yang mengandung pola nonlinear yaitu pola ESTAR(1) untuk skenario 2 dengan persamaan sebagai berikut:

$$N_{1,t} = 0,7N_{1,t-1} + a_t \text{ dengan } a_t \sim N(0,1) \quad (3.5)$$

$$N_{2,t} = 6,5N_{2,t-1} \exp(-0,25N_{2,t-1}^2) + a_t \text{ dengan } a_t \sim N(0,1) \quad (3.6)$$

Selanjutnya persamaan 3.5 dan persamaan 3.6 dikalikan dengan angka 30. Hal ini dilakukan agar pola linear dan non linear lebih terlihat. Kemudian, melakukan pemodelan dengan model ARIMAX, DNN, Hibrida ARIMAX-DNN. Selanjutnya, membandingkan kebaikan model pada model ARIMAX, DNN, Hibrida ARIMAX-DNN dengan RMSEP dan SMAPEP dan menarik kesimpulan.

## 3.2 Kajian Terapan

### 3.2.1 Sumber Data

Data yang digunakan pada penelitian ini adalah data sekunder dari divisi Perencanaan dan Evaluasi (Renew) PT.PLN (Persero) P2B-APB Wilayah Jawa Tengah dan DIY. Data yang digunakan merupakan data beban konsumsi listrik per setengah jam wilayah Jateng dan DIY.

**Tabel 3.2** Daftar Hari Libur Selain Minggu Tahun 2013 hingga 2017

Dummy	Keterangan	2013		2014		2015		2016		2017	
		Tanggal	Hari	Tanggal	Hari	Tanggal	Hari	Tanggal	Hari	Tanggal	Hari
DV1	Tahun Baru	1 Jan 2013	Selasa	1 Jan 2014	Rabu	1 Jan 2015	Kamis	1 Jan 2016	Jumat		
DV2	Maulid Nabi	24 Jan 2013	Kamis	14 Jan 2014	Selasa	3 Jan 2015	Sabtu	12 Dec 2016	Senin	1 Dec 2017	Jumat
DV3	Tahun Baru Imlek			31 Jan 2014	Jumat	24 Dec 2015	Kamis	8 Feb 2016	Senin	28 Jan 2017	Sabtu
DV4	Hari Raya Nyepi	12 Mar 2013	Selasa	31 Mar 2014	Senin	19 Feb 2015	Kamis	9 Mar 2016	Rabu	28 Mar 2017	Selasa
DV5	Wafat Isa Almasih	29 Mar 2013	Jumat	18 Apr 2014	Jumat	21 Mar 2015	Sabtu	25 Mar 2016	Jumat	14 Apr 2017	Jumat
DV6	Hari Buruh			1 May 2014	Kamis	3 Apr 2015	Jumat			1 May 2017	Senin
DV7	Kenaikan Isa Almasih	19 Apr 2013	Kamis	1 May 2015	Kamis	1 May 2015	Jumat	5 May 2016	Kamis	25 May 2017	Kamis
DV8	Hari Raya Waisak	25 Apr 2013	Kamis	29 May 2015	Kamis	14 May 2015	Kamis				
DV9	Isra Miraj	6 May 2013	Senin	15 May 2014	Kamis	2 Jun 2015	Selasa			11 May 2017	Kamis
DV10	Hari Kemerdekaan	17 Aug 2013	Sabtu	27 May 2014	Selasa	16 May 2015	Sabtu	6 May 2016	Jumat	24 Apr 2017	Senin
DV11	H-3 HRIF	5 Aug 2013	Senin			17 Aug 2015	Senin	17 Aug 2016	Rabu	17 Aug 2017	Kamis
DV12	H-2 HRIF	6 Aug 2013	Selasa	26 Jul 2014	Sabtu			4 Jul 2016	Senin	23 Jun 2017	Jumat
DV13	H-1 HRIF	7 Aug 2013	Rabu			16 Jul 2015	Kamis	5 Jul 2016	Selasa	24 Jun 2017	Sabtu
DV14	HRIF 1	8 Aug 2013	Kamis	28 Jul 2014	Senin	17 Jul 2015	Jumat	6 Jul 2016	Rabu	25 Jun 2017	Minggu
DV15	HRIF 2	9 Aug 2013	Jumat	29 Jul 2014	Selasa	18 Jul 2015	Sabtu	7 Jul 2016	Kamis	26 Jun 2017	Senin
DV16	H+1 HRIF	10 Aug 2013	Sabtu	30 Jul 2014	Rabu			8 Jul 2016	Jumat	27 Jun 2017	Selasa
DV17	H+2 HRIF			31 Jul 2014	Kamis	20 Jul 2105	Senin	9 Jul 2016	Sabtu	28 Jun 2017	Rabu
DV18	H+3 HRIF	12 Aug 2013	Senin	1 Aug 2014	Jumat	21 Jul 2105	Selasa				
DV19	Hari Raya Idul Adha	15 Oct 2013	Selasa			24 Sep 2015	Kamis	12 Sep 2016	Senin	1 Sep 2017	Jumat
DV20	Hari Tahun Baru Hijriyah	5 Nov 2013	Selasa	25 Oct 2014	Sabtu	14 Oct 2015	Rabu			21 Sep 2017	Kamis
DV21	Hari Raya Natal	25 Dec 2013	Rabu	25 Dec 2014	Kamis	25 Dec 2015	Jumat			25 Dec 2017	Senin

### 3.2.2 Variabel penelitian

Variabel penelitian yang digunakan pada penelitian ini adalah beban konsumsi listrik per setengah jam periode Januari 2013 hingga Desember 2017. Pada analisis penelitian ini, data akan dibagi menjadi dua bagian yaitu data *in sample* dan data *out sample*. Pada data *in sample* akan digunakan data beban listrik jangka pendek per setengah jam periode Januari 2013 hingga Desember 2016. Sedangkan data *out sample* akan digunakan data beban listrik jangka pendek per setengah jam periode Januari 2017 hingga Desember 2017. Peramalan konsumsi listrik akan dilakukan per setengah jam sehingga akan dihasilkan 48 model peramalan.

Penggunaan ARIMAX dipengaruhi oleh variabel *dummy* yang didasarkan tipe hari dalam minggu dan efek variasi kalender. Berikut penentuan variabel *dummy* pada model ARIMAX yang dapat dituliskan sebagai berikut:

1. Variabel *dummy* untuk tipe hari dalam seminggu, dapat dijelaskan sebagai berikut:

$$D_{q,t}^w = \begin{cases} 1, & \text{untuk hari ke-} q \\ 0, & \text{untuk yang lain} \end{cases}$$

$$q : 1, 2, \dots, 7$$

2. Variabel *dummy* untuk efek variasi kalender. Diasumsikan efek variasi kalender adalah efek hari libur selain hari minggu.

$$D_{r,t}^v = \begin{cases} 1, & \text{untuk efek kalender variasi ke-} r \\ 0, & \text{bukan untuk efek kalender variasi ke-} r \end{cases}$$

### 3.2.3 Struktur Data

Struktur data yang digunakan dalam penelitian ini adalah sebagai berikut:

**Tabel 3.3** Struktur Data Penelitian

Tahun	Bulan	Tanggal	Waktu			
			00:30	01:00	...	00:00
2013	Januari	1	$Z_{1,1}$	$Z_{1,2}$	...	$Z_{1,48}$
2013	Januari	2	$Z_{2,1}$	$Z_{2,2}$	...	$Z_{2,48}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2013	Januari	30	$Z_{30,1}$	$Z_{30,2}$	...	$Z_{30,48}$
2013	Januari	31	$Z_{31,1}$	$Z_{31,2}$	...	$Z_{31,48}$
2013	Februari	1	$Z_{32,1}$	$Z_{32,2}$	...	$Z_{32,48}$
2013	Februari	2	$Z_{33,1}$	$Z_{33,2}$	...	$Z_{33,48}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2013	Februari	27	$Z_{58,1}$	$Z_{58,2}$	...	$Z_{58,48}$
201	Februari	28	$Z_{59,1}$	$Z_{59,2}$	...	$Z_{59,1}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2017	Desember	1	$Z_{1796,1}$	$Z_{1796,2}$	...	$Z_{1796,48}$
2017	Desember	2	$Z_{1797,1}$	$Z_{1797,2}$	...	$Z_{1797,48}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2017	Desember	31	$Z_{1825,1}$	$Z_{1825,2}$	...	$Z_{1825,48}$
2017	Desember	31	$Z_{1826,1}$	$Z_{1826,2}$	...	$Z_{1826,48}$

### 2.3.4 Langkah Analisis

Berikut merupakan langkah analisis untuk kajian terapan:

1. Mendeskripsikan data beban listrik jangka pendek per setengah jam area Jawa Tengah dan DIY.
2. Membagi data menjadi data *in sample* dan data *out sample*. Untuk *data in sample* yaitu data beban listrik jangka pendek per setengah jam periode Januari 2013 hingga Desember 2016 sedangkan untuk data *out sample* yaitu data beban listrik jangka pendek per setengah jam periode Januari 2017 hingga Desember 2017. Langkah selanjutnya, membentuk model peramalan untuk data beban listrik jangka pendek per setengah jam area Jawa Tengah dan DIY dengan model ARIMAX, *Deep Neural Network*, dan Hibrida ARIMAX dan *Deep Neural Network*.

Berikut merupakan langkah-langkah analisis menggunakan model ARIMAX:

- a. Menentukan variabel *dummy* untuk periode variasi kalender.
- b. Meregresikan variabel respon dan variabel prediktor.
- c. Melakukan cek diagnosa *residual*.
- d. Memodelkan *residual* dengan ARIMA.
- e. Melakukan estimasi parameter model dan menguji signifikansi parameter model.
- f. Melakukan pengujian diagnosa residual. Pada penelitian ini tidak dilakukan permodelan dengan deteksi outlier sehingga apabila terdapat asumsi yang tidak terpenuhi, analisis tetap dilanjutkan.
- g. Melakukan peramalan dengan model ARIMAX dengan persamaan 2.2.
- h. Menghitung nilai RMSEP dan sMAPEP dari hasil peramalan.

Berikut merupakan langkah-langkah analisis menggunakan model DNN:

- a. Melakukan *preprocessing* data dengan menggunakan normalisasi dengan persamaan.

$$Y_t^* = \frac{Y_t - \min(Y_t)}{\max(Y_t) - \min(Y_t)} \quad (3.7)$$

- b. Mengidentifikasi apakah data linear atau tidak dengan menggunakan Uji White.
- c. Menentukan arsitektur pada DNN seperti input dan jumlah neuron. Input yang digunakan pada DNN adalah komponen tren, musiman, dan kalender variasi pada ARIMAX dan lag variabel lag variabel respon PACF yang signifikan. Untuk penentuan jumlah neuron pada DNN akan dilakukan percobaan kombinasi 1 hingga 5 untuk masing-masing hidden layer.
- d. Melakukan peramalan menggunakan DNN dengan persamaan 2.37.
- e. Melakukan *postprocessing* data dengan persamaan.




$$Y_t = Y_t^* (\max(Y_t) - \min(Y_t)) + \min(Y_t) \quad (3.8)$$

- f. Menghitung nilai RMSEP dan sMAPEP dari hasil peramalan.

Berikut merupakan langkah-langkah analisis menggunakan model hibrida ARIMAX-DNN:


- a. Melakukan permodelan dan peramalan data asli dengan menggunakan ARIMAX.
  - b. Menghitung residual ARIMAX dengan persamaan 2.55.
  - c. Melakukan permodelan dan peramalan data *residual* ARIMAX dengan menggunakan DNN. Input yang digunakan pada DNN adalah komponen pada ARIMAX yaitu komponen model ARIMA, komponen tren, komponen musiman harian dan kalender variasi. Untuk penentuan jumlah neuron pada DNN akan dilakukan percobaan kombinasi 1 hingga 5 untuk masing-masing hidden layer.
  - d. Melakukan peramalan dengan hibrida ARIMAX-DNN dengan persamaan 2.57.
  - e. Menghitung nilai RMSEP dan sMAPE dari hasil peramalan.
3. Memilih model terbaik dari ARIMAX, DNN dan hibrida ARIMAX-DNN dengan membandingkan nilai RMSEP dan sMAPEP.

Langkah-langkah analisis di atas dapat digambarkan dalam diagram alir pada Gambar 3.1.




**Gambar 3.1** Langkah Analisis Kajian Terapan

Langkah-langkah analisis untuk model ARIMAX dapat disajikan dalam Gambar 3.2.




**Gambar 3.2** Langkah Analisis Model ARIMAX

Langkah-langkah analisis untuk model DNN dapat disajikan dalam Gambar 3.3 berikut:




**Gambar 3.3** Langkah Analisis Model *Deep Learning*

Proses analisis untuk model ARIMAX dapat disajikan dalam Gambar 3.4 berikut




**Gambar 3.4** Proses ARIMAX

Proses analisis untuk model DNN dapat disajikan dalam Gambar 3.5 berikut:



**Gambar 3.5** Proses DNN

Proses analisis untuk model Hibrida ARIMAX dan *Deep Neural Network* dapat disajikan dalam Gambar 3.6 berikut



**Gambar 3.6** Proses Model Hibrida ARIMAX dan *Deep Neural Network*

*(halaman ini sengaja dikosongkan)*



## BAB IV

### ANALISIS DAN PEMBAHASAN


Pada bab ini akan dilakukan analisis dan pembahasan yang mencakup dua kajian yaitu kajian simulasi dan kajian terapan. Model ARIMAX, *Deep Neural Network*, dan Hibrida ARIMAX-*Deep Neural Network* akan diterapkan pada data simulasi dan data beban listrik jangka pendek wilayah Jawa Tengah dan DIY serta membandingkan performa masing-masing model mengenai peramalan menggunakan model ARIMAX, *Deep Neural Network*, dan Hibrida ARIMAX-*Deep Neural Network*.

#### 4.1 Kajian Simulasi


Kajian simulasi dilakukan bertujuan untuk membuktikan bahwa suatu model layak digunakan serta mengetahui kebaikan model ARIMAX, DNN, maupun Hibrida ARIMAX-DNN dalam memodelkan dengan adanya linieritas dan nonlinieritas pada data.

##### 4.1.1 Simulasi Data Bangkitan

Kajian simulasi pada penelitian ini terdiri dari dua skenario yaitu simulasi dengan *noise* linear dan simulasi dengan *noise* nonlinear. Berikut merupakan plot untuk komponen tren, musiman, variasi kalender, dan *noise* untuk beban listrik jam 20:00 sebagai acuan dalam melakukan kajian simulasi ini:




**Gambar 4.1** Plot Data Beban Listrik Jam 04:00 untuk Komponen (a) Tren (b) Musiman (c) Variasi Kalender (d) Noise Linear (e) Noise Nonlinear



**Gambar 4.1** Plot Data Beban Listrik Jam 04:00 untuk Komponen (a) Tren (b) Musiman (c) Variasi Kalender (d) Noise Linear (e) Noise Nonlinear (lanjutan)

Berikut merupakan lagplot untuk melihat noise yang mengikuti pola linear dan pola nonlinear:




**Gambar 4.2** Scatter Plot antara Noise ( $N_t$ ) dan Lag Noise ( $N_{t-1}$ ) (a) Linear (b) Nonlinear

Pada Gambar 4.2 (a) dapat dilihat antara noise dan lag 1 memiliki pola yang linear. Sedangkan pada Gambar 4.2 (a) dapat dilihat antara noise dan lag 1 memiliki pola yang linear

### 1. Skenario 1

Pada skenario 1 akan digunakan data simulasi yang mengandung komponen tren, musiman, variasi kalender, dan *noise* yang mengikuti pola linear yaitu mengikuti pola AR(1). Berikut merupakan plot *time series* untuk data skenario 1 jam 04:00, 08:00, 12:00, 16:00, 20:00, dan 24:00:



**Gambar 4.3** Plot *Time Series* Skenario 1 jam (a) 04:00, (b) 08:00, (c) 12:00, (d) 16:00, (e) 20:00, dan (f) 24:00

Berdasarkan Gambar 4.3 dapat diketahui bahwa dari keenam plot *time series* dengan waktu yang berbeda memiliki karakteristik yang hampir sama. Data simulasi memiliki tren naik dengan musiman 7 hari. Variasi kalender yang memiliki dampak paling tinggi saat H-3 sebelum Hari Raya Idul Fitri, 2 Hari Raya Idul Fitri, dan H+3 setelah Hari Raya Idul Fitri. Permodelan pertama yang dilakukan adalah ARIMAX. Pada kajian simulasi akan dilakukan permodelan ARIMAX untuk data simulasi jam 04:00, 08:00, 12:00, 16:00, 20:00, 24:00. Langkah pertama dalam permodelan ARIMAX yaitu regresi *time series*. Selanjutnya dilakukan estimasi parameter regresi *time series* pada skenario 1. Estimasi parameter regresi *time series* untuk data simulasi jam 20:00 dapat dilihat pada Tabel 4.1 berikut:

**Tabel 4.1** Estimasi Parameter Regresi *Time Series* Skenario 1

Variabel	Estimasi	SE	<i>t</i> -value	<i>p</i> -value
$\phi_1$	0,72	0,01831	39,51	<0,0001
T	0,30	0,006687	44,93	<0,0001
$D_1^W$	3533,6	5,91343	597,56	<0,0001
$D_2^W$	3558,8	5,90397	602,78	<0,0001
$D_3^W$	3559,7	5,91288	602,02	<0,0001
$D_4^W$	3547,8	5,92628	598,65	<0,0001
$D_5^W$	3507,5	5,9311	591,38	<0,0001
$D_6^W$	3435,4	5,92304	580	<0,0001
$D_7^W$	3343,1	5,91828	564,88	<0,0001
$D_1^V$	-518,09	12,23813	-42,33	<0,0001
$D_2^V$	-269,05	11,03242	-24,39	<0,0001
$D_3^V$	-289,19	14,11727	-20,48	<0,0001
$D_4^V$	-248,92	12,22191	-20,37	<0,0001
$D_5^V$	-204,28	12,32537	-16,57	<0,0001
$D_6^V$	-242,76	17,28573	-14,04	<0,0001
$D_7^V$	-69,44	12,34576	-5,62	<0,0001
$D_8^V$	-92,09	14,15232	-6,51	<0,0001
$D_9^V$	-85,78	12,31185	-6,97	<0,0001
$D_{10}^V$	-202,98	14,12872	-14,37	<0,0001
$D_{11}^V$	-379,76	15,08081	-25,18	<0,0001
$D_{12}^V$	-360,78	18,57996	-19,42	<0,0001
$D_{13}^V$	-658,95	20,09254	-32,8	<0,0001
$D_{14}^V$	-839,94	20,68303	-40,61	<0,0001
$D_{15}^V$	-673,70	20,68107	-32,58	<0,0001
$D_{16}^V$	-679,99	20,0875	-33,85	<0,0001
$D_{17}^V$	-528,58	18,57377	-28,46	<0,0001
$D_{18}^V$	-452,22	15,07666	-29,99	<0,0001
$D_{19}^V$	-140,84	14,12442	-9,97	<0,0001
$D_{20}^V$	-117,51	14,11717	-8,32	<0,0001
$D_{21}^V$	-179,53	14,21484	-12,63	<0,0001

Pada Tabel 4.1 dapat dilihat semua variabel yang memiliki *p*-value yang kurang dari  $\alpha$  (0,05). Artinya semua variabel berpengaruh signifikan terhadap data simulasi. Setelah dilakukan estimasi parameter untuk regresi *time series*, dilakukan pengujian

pada residual apakah residual memenuhi asumsi *white noise* dan berdistribusi normal. Apabila asumsi residual belum terpenuhi, maka perlu dilakukan permodelan dengan ARIMA. Setelah dilakukan uji asumsi residual pada data, didapatkan model untuk residual regresi *time series* adalah AR (1).

Selanjutnya dilakukan pengujian asumsi pada residual model ARIMA yaitu residual *white noise* dan berdistribusi normal. Hasil pengujian asumsi pada residual ARIMA pada skenario 1 ditunjukkan pada Tabel 4.2.

**Tabel 4.2** Hasil Uji White Noise dan Normalitas pada Residual Skenario 1

Lag ke-	Uji White noise			Uji Normalitas
	$\chi^2$	df	p-value	p-value
6	0,79	5	0,9774	D=0,015711 P-value=>0,1500
12	5,34	11	0,9135	
18	16,84	17	0,4654	
24	20,12	23	0,6347	
30	24,73	29	0,6923	
36	33,73	35	0,5292	
42	37,95	41	0,6068	
48	52,3	47	0,2758	

Dapat diketahui dari Tabel 4.2 bahwa residual sudah memenuhi asumsi *white noise* dikarenakan semua *p-value* memiliki nilai yang lebih dari  $\alpha$  (0,05) dan residual telah berdistribusi normal karena memiliki nilai *p-value* yang lebih dari  $\alpha$  (0,05). Sehingga model persamaan data simulasi skenario 1 untuk jam 20:00 ( $Y_{40,t}$ ) memiliki fungsi sebagai berikut:


$$\begin{aligned}
 Y_{40,t} = & 0,30t + 3533,6D_{1,t}^W + 3558,8D_{2,t}^W + 3559,7D_{3,t}^W + 3547,8D_{4,t}^W \\
 & + 3507,5D_{5,t}^W + 3435,4D_{6,t}^W + 3343,1D_{7,t}^W - 518,09D_{1,t}^V - 269,06D_{2,t}^V \\
 & - 289,19D_{3,t}^V - 248,92D_{4,t}^V - 204,28D_{5,t}^V - 242,76D_{6,t}^V - 69,44D_{7,t}^V \\
 & - 92,09D_{8,t}^V - 85,78D_{9,t}^V - 202,98D_{10,t}^V - 379,76D_{11,t}^V + 360,78D_{12,t}^V \\
 & - 658,95D_{13,t}^V - 839,94D_{14,t}^V - 673,70D_{15,t}^V - 679,99D_{16,t}^V - 528,58D_{17,t}^V \\
 & - 452,22D_{18,t}^V - 140,84D_{19,t}^V - 117,51D_{20,t}^V - 179,53D_{21,t}^V + \frac{1}{(1-0,72B)}a_t
 \end{aligned}$$

Dengan cara yang sama, dilakukan permodelan ARIMAX untuk data simulasi untuk jam 08:00, 12:00, 16:00, 20:00, 24:00. Berdasarkan pendugaan model pada beberapa waktu didapatkan model terbaik ARIMA dengan hasil pada Tabel 4.3.


**Tabel 4.3** Komponen ARIMA pada Model ARIMAX untuk Data Simulasi Skenario 1 Masing-masing waktu

Jam	Model	Residual	Residual
		White noise	Berdistribusi Normal
04:00	AR (1)	Ya	Ya
08:00	AR (1)	Ya	Ya
12:00	AR (1)	Ya	Ya
16:00	AR (1)	Ya	Ya
20:00	AR (1)	Ya	Ya
24:00	AR (1)	Ya	Ya

Berdasarkan model persamaan pada Tabel 4.3 dilakukan perbandingan data aktual dan ramalan, yang ditunjukkan pada Gambar 4.4 sebagai berikut:



**Gambar 4.4** Perbandingan Data Aktual dan Ramalan Beberapa Waktu untuk Simulasi Skenario 1 dengan Model ARIMAX




**Gambar 4.4** Perbandingan Data Aktual dan Ramalan Beberapa Waktu untuk Simulasi Skenario 1 dengan Model ARIMAX (lanjutan)

Pada Gambar 4.4 menunjukkan bahwa model ARIMAX cukup baik dalam meramalkan pada data *training*. Hal ini dapat dilihat dari hasil ramalan cenderung mengikuti pola data aktual pada data *training* dan data *testing*.

Analisis selanjutnya akan dilakukan permodelan dengan *deep neural network* pada data simulasi skenario 1. Sebelum dilakukan permodelan dengan DNN, dilakukan *preprocessing* pada data simulasi skenario 1 dengan menggunakan normalisasi.

Pada penelitian ini akan digunakan dua *hidden layer* dengan masing-masing *hidden layer* merupakan kombinasi 1 sampai dengan 5 neuron dan digunakan fungsi aktivasi sigmoid untuk masing-masing *hidden layer* dan fungsi aktivasi identitas untuk *output layer*sertadilakukan replikasi sebanyak 10 kali. Input yang digunakan pada model DNN adalah komponen tren, musiman, kalender variasi pada ARIMAX dan lag variabel respon berdasarkan PACF yang signifikan. Plot PACF untuk data simulasi skenario 1 untuk jam 20:00 akan ditampilkan pada Gambar 4.5.



**Gambar 4.5** Plot PACF untuk Data Simulasi Skenario 1 pada jam 20:00

Berdasarkan Gambar 4.5, input yang akan digunakan pada model DNN adalah lag 1, 2, 4-15, 17-19, 21, 22, 25-29, 32, 35, 36, 38, 42, dan 43. Komponen ARIMAX yang juga masuk ke dalam input pada DNN antara lain  $T$ ,  $D_1^W$ ,  $D_2^W$ ,  $D_3^W$ ,  $D_4^W$ ,  $D_5^W$ ,  $D_6^W$ ,  $D_7^W$ ,  $D_1^V$ ,  $D_2^V$ ,  $D_3^V$ ,  $D_4^V$ ,  $D_5^V$ ,  $D_6^V$ ,  $D_7^V$ ,  $D_8^V$ ,  $D_9^V$ ,  $D_{10}^V$ ,  $D_{11}^V$ ,  $D_{12}^V$ ,  $D_{13}^V$ ,  $D_{14}^V$ ,  $D_{15}^V$ ,  $D_{16}^V$ ,  $D_{17}^V$ ,  $D_{18}^V$ ,  $D_{19}^V$ ,  $D_{20}^V$  dan  $D_{21}^V$ . Untuk data simulasi skenario 1 pada jam 20:00 didapatkan arsitektur DNN optimum adalah 5 neuron pada *hidden layer* 1 dan 5 neuron pada *hidden layer* 2 yang akan ditampilkan pada Gambar 4.6. Sedangkan persamaan model DNN untuk beban listrik pada jam 20:00 ( $Y_{40,t}$ ) akan ditampilkan sebagai berikut:

$$Y_{40,t}^* = 0,16 + 1,01fh_1^2(.) + 1,08fh_2^2(.) + 2,06fh_3^2(.) - 3,19fh_4^2(.)$$

dengan

$$fh_1^2(.) = (1 + \exp(-(0,09 + 0,71fh_1^1(.) - 0,71fh_1^1(.))))^{-1}$$

$$fh_2^2(.) = (1 + \exp(-(0,34 + 2,15fh_1^1(.) - 2,84fh_2^1(.))))^{-1}$$







**Tabel 4.4** Arsitektur untuk Permodelan DNN pada Skenario 1

Jam	Input PACF	Jumlah neuron	
		Hidden 1	Hidden 2
04:00	1, 2, 4-8, 10-13, 15, 17, 18, 20-22, 25-27, 29, 31, 32, 35, 36, 38, 40, 43, 46	3	4
08:00	1-9, 11-16, 18-22, 26-29, 35, 38, 41, 42	1	2
12:00	1, 2, 5-16, 18-22, 26, 28, 29, 35, 36, 42	1	4
16:00	1, 3, 6-22, 25, 26, 28, 29, 35, 36, 38, 42, 43, 46, 47	1	2
20:00	1, 2, 4-15, 17-19, 21, 22, 25-29, 32, 35, 36, 38, 42, 43	2	4
24:00	1-15, 17-22, 25, 26, 28, 29, 35, 36, 38, 42, 43, 46	1	4

Berdasarkan arsitektur optimum pada Tabel 4.4 dilakukan perbandingan data aktual dan ramalan, yang ditunjukkan pada Gambar 4.7 sebagai berikut:



**Gambar 4.7** Perbandingan Data Aktual Skenario 1 dan Ramalan dengan menggunakan model DNN



**Gambar 4.7** Perbandingan Data Aktual Skenario 1 dan Ramalan dengan menggunakan model DNN (lanjutan)

Pada Gambar 4.7 menunjukkan bahwa dengan model DNN yang diterapkan pada data simulasi skenario 1 cukup baik dalam meramalkan pada data *training*. Hal ini dapat dilihat dari hasil ramalan cenderung mengikuti pola data aktual pada data *training*. Sedangkan perbandingan hasil ramalan pada data *testing* juga cukup mampu menangkap pola, sehingga hasil ramalan cenderung mengikuti pola data aktual pada data *testing*.

Analisis selanjutnya yang akan dilakukan untuk data simulasi skenario 1 adalah permodelan dengan hibrida ARIMAX-DNN. Data yang digunakan untuk permodelan hibrida ARIMAX-DNN merupakan residual dari model ARIMAX yang telah dilakukan sebelumnya. Setelah mendapatkan data residual, data tersebut terlebih dahulu dinormalisasi sebagai tahap *preprocessing*. Arsitektur DNN pada model Hibrida ARIMAX-DNN memiliki dua *hidden layer* dengan masing-masing *hidden layer* merupakan kombinasi 1 sampai dengan 5 neuron dan digunakan fungsi aktivasi sigmoid untuk masing-masing *hidden layer* dan fungsi aktivasi identitas untuk *output layer* serta akan dilakukan 10 replikasi. Input yang digunakan pada analisis ini adalah lag PACF signifikan dari komponen ARIMAX dan input yang sama seperti ARIMAX yaitu komponen tren ( $T$ ), komponen musiman harian ( $D_1^W, D_2^W, D_3^W, D_4^W, D_5^W, D_6^W, D_7^W$ ) dan komponen kalender variasi ( $D_1^V, D_2^V, D_3^V, D_4^V, D_5^V, D_6^V, D_7^V, D_8^V, D_9^V, D_{10}^V, D_{11}^V, D_{12}^V, D_{13}^V, D_{14}^V, D_{15}^V, D_{16}^V, D_{17}^V, D_{18}^V, D_{19}^V, D_{20}^V$ , dan  $D_{21}^V$ ). Pada jam 20:00 input yang digunakan adalah 1 karena model ARIMA untuk komponen ARIMAX adalah AR(1). Sehingga didapatkan arsitektur DNN optimum adalah 4 neuron pada *hidden layer* 1 dan 5 neuron pada *hidden layer* 2 yang akan ditampilkan pada Gambar 4.8. Sedangkan persamaan model DNN untuk data skenario 1 pada jam 20:00 ( $\hat{Y}_{40,t}$ ) akan ditampilkan sebagai berikut:

$\hat{Y}_{40,t} = \hat{L}_t + \hat{N}_t$  dengan  $\hat{N}_t$  merupakan hasil normalisasi dari  $\hat{N}_t^*$

dimana

$$\begin{aligned} \hat{L}_t = & 0,30t + 3533,6D_{1,t}^W + 3558,8D_{2,t}^W + 3559,7D_{3,t}^W + 3547,8D_{4,t}^W \\ & + 3507,5D_{5,t}^W + 3435,4D_{6,t}^W + 3343,1D_{7,t}^W - 518,09D_{1,t}^V - 269,06D_{2,t}^V \\ & - 289,19D_{3,t}^V - 248,92D_{4,t}^V - 204,28D_{5,t}^V - 242,76D_{6,t}^V - 69,44D_{7,t}^V \\ & - 92,09D_{8,t}^V - 85,78D_{9,t}^V - 202,98D_{10,t}^V - 379,76D_{11,t}^V + 360,78D_{12,t}^V \\ & - 658,95D_{13,t}^V - 839,94D_{14,t}^V - 673,70D_{15,t}^V - 679,99D_{16,t}^V - 528,58D_{17,t}^V \\ & - 452,22D_{18,t}^V - 140,84D_{19,t}^V - 117,51D_{20,t}^V - 179,53D_{21,t}^V + \frac{1}{(1-0,72B)}a_t \end{aligned}$$

$\hat{N}_t^* = 0,75 + 0,75 fh_1^2(.) + 0,30 fh_2^2(.) - 0,38 fh_3^2(.) - 1,78 fh_4^2(.) + 0,30 fh_5^2(.)$   
dengan

$$fh_1^2(.) = (1 + \exp(-(-0,36 - 10,74 fh_1^1(.) - 0,26 fh_2^1(.) + 3,08 fh_3^1(.) - 298,56 fh_4^1(.))))^{-1}$$

$$fh_2^2(.) = (1 + \exp(-(-68,09 + 1243,25 fh_1^1(.) - 4,90 fh_2^1(.) + 70,59 fh_3^1(.) + 23,77 fh_4^1(.))))^{-1}$$

$$fh_3^2(.) = (1 + \exp(-(-96,62 - 94,32 fh_1^1(.) - 29,78 fh_2^1(.) - 222,27 fh_3^1(.) - 104,00 fh_4^1(.))))^{-1}$$

$$fh_4^2(.) = (1 + \exp(-(-0,65 - 2,64 fh_1^1(.) - 3,83 fh_2^1(.) + 2,58 fh_3^1(.) - 0,23 fh_4^1(.))))^{-1}$$

$$fh_5^2(.) = (1 + \exp(-(-19,61 - 200,60 fh_1^1(.) - 72,12 fh_2^1(.) + 127,73 fh_3^1(.) - 39,88 fh_4^1(.))))^{-1}$$

dengan

$$fh_1^1(.) = (1 + \exp(-(2,48 - 2,91Y_{t-1} + 0,02Y_{t-2} + \dots + 35,55D_{21}^v)))^{-1}$$

$$fh_2^1(.) = (1 + \exp(-(1,62 + 1,88Y_{t-1} + 3,50Y_{t-2} + \dots + 0,15D_{21}^v)))^{-1}$$


$$fh_3^1(.) = (1 + \exp(-(1,58 + 4,28Y_{t-1} + 0,02Y_{t-2} + \dots - 3,10D_{21}^v)))^{-1}$$

$$fh_4^1(.) = (1 + \exp(-(-1,43 + 1,42Y_{t-1} - 0,60Y_{t-2} + \dots - 271,26D_{21}^v)))^{-1}$$

Berikut merupakan arsitektur model hibrida ARIMAX-DNN untuk masing-masing waktu:


**Tabel 4.5** Arsitektur untuk Model Hibrida ARIMAX-DNN pada Skenario 1

Jam	Input	Jumlah neuron	
		Hidden 1	Hidden 2
04:00	1	5	1
08:00	1	1	1
12:00	1	1	2
16:00	1	4	3
20:00	1	4	5
24:00	1	4	2




**Gambar 4.8** Arsitektur DNN pada Model Hibrida ARIMAX-DNN untuk Data Simulasi Skenario 1 pada jam 20:00

Berdasarkan arsitektur optimum pada Tabel 4.5 dilakukan perbandingan data aktual dan ramalan, yang ditunjukkan pada Gambar 4.9 sebagai berikut:



**Gambar 4.9** Perbandingan Data Aktual Skenario 1 dan Ramalan dengan Menggunakan Model Hibrida ARIMAX-DNN




**Gambar 4.9** Perbandingan Data Aktual Skenario 1 dan Ramalan dengan Menggunakan Model Hibrida ARIMAX-DNN (lanjutan)

Pada Gambar 4.9 menunjukkan bahwa dengan model Hibrida ARIMAX-DNN yang diterapkan pada data simulasi skenario 1 cukup baik dalam meramalkan pada data *training* dan data *testing*. Hal ini dapat dilihat dari hasil ramalan mengikuti pola data aktual pada data *training* dan data *testing*.

## 2. Skenario 2

Pada skenario 2 akan digunakan data simulasi yang mengandung komponen tren, musiman, variasi kalender, dan *noise* yang mengikuti pola nonlinear yaitu mengikuti pola ESTAR(1). Berikut merupakan *plot time series* untuk data skenario 2 jam 04:00, 08:00, 12:00, 16:00, 20:00, dan 24:00:



**Gambar 4.10** Plot *time series* Skenario 2 jam (a) 04:00, (b) 08:00, (c) 12:00, (d) 16:00, (e) 20:00, dan (f) 24:00

Dapat dilihat pada Gambar 4.10 keenam plot *time series* memiliki tren naik dengan musiman 7 hari. Berdasarkan Gambar 4.3 pada jam 08:00 memiliki beban paling tinggi. Permodelan



pertama yang dilakukan adalah ARIMAX. Pada kajian simulasi akan dilakukan permodelan ARIMAX untuk data simulasi jam 04:00, 08:00, 12:00, 16:00, 20:00, 24:00. Langkah pertama dalam permodelan ARIMAX yaitu regresi *time series*. Selanjutnya dilakukan estimasi parameter regresi *time series* pada skenario 2. Estimasi parameter regresi *time series* untuk data simulasi jam 20:00 dapat dilihat pada Tabel 4.6 berikut:

**Tabel 4.6** Estimasi Parameter Regresi *Time Series* Skenario 2

Variabel	Estimasi	SE	<i>t</i> -value	<i>p</i> -value
$\theta_1$	0,38	0,07024	5,35	<0,0001
$\phi_2$	0,64	0,0581	11,06	<0,0001
T	0,32	0,01033	30,67	<0,0001
$D_1^W$	3528,9	10,44792	337,76	<0,0001
$D_2^W$	3543,9	10,43513	339,62	<0,0001
$D_3^W$	3554,7	10,43317	340,71	<0,0001
$D_4^W$	3541,7	10,49104	337,59	<0,0001
$D_5^W$	3484,5	10,49775	331,93	<0,0001
$D_6^W$	3428,7	10,44578	328,24	<0,0001
$D_7^W$	3332,3	10,43427	319,36	<0,0001
$D_1^V$	-452,38	46,06074	-9,82	<0,0001
$D_2^V$	-280,86	41,28312	-6,8	<0,0001
$D_3^V$	-306,17	53,1874	-5,76	<0,0001
$D_4^V$	-242,28	46,01766	-5,26	<0,0001
$D_5^V$	-136,59	46,39331	-2,94	0,0033
$D_6^V$	-246,42	65,17377	-3,78	0,0002
$D_7^V$	-14,88	46,39747	-0,32	0,7484
$D_8^V$	-33,33	53,25941	-0,63	0,5316
$D_9^V$	-84,53	46,26364	-1,83	0,0679
$D_{10}^V$	-240,81	53,16437	-4,53	<0,0001
$D_{11}^V$	-351	48,00062	-7,31	<0,0001
$D_{12}^V$	-344,26	49,70084	-6,93	<0,0001
$D_{13}^V$	-652,66	50,38134	-12,95	<0,0001
$D_{14}^V$	-881,52	50,60315	-17,42	<0,0001
$D_{15}^V$	-682,71	50,57864	-13,5	<0,0001
$D_{16}^V$	-658,11	50,31776	-13,08	<0,0001
$D_{17}^V$	-574,49	49,62794	-11,58	<0,0001
$D_{18}^V$	-411,20	47,92431	-8,58	<0,0001

**Tabel 4.6** Estimasi Parameter Regresi *Time Series* Skenario 2 (lanjutan)

Variabel	Estimasi	SE	<i>t</i> -value	<i>p</i> -value
$D_{19}^V$	-147,78	53,20144	-2,78	0,0055
$D_{20}^V$	-198,66	53,1509	-3,74	0,0002
$D_{21}^V$	-99,44	53,24093	-1,87	0,062

Berdasarkan Tabel 4.6 dapat dilihat ada beberapa variabel yang memiliki *p*-value yang lebih dari  $\alpha$  (0,05). Artinya terdapat variabel yang tidak berpengaruh signifikan terhadap data simulasi. Kemudian dilakukan pengujian pada residual apakah residual memenuhi asumsi *white noise* dan berdistribusi normal. Apabila residual belum memenuhi asumsi, maka akan dilakukan prosedur ARIMA terhadap data residual regresi *time series*. Pada data simulasi jam 20:00 didapatkan model AR (1,2). Hasil pengujian asumsi pada residual ARIMA pada skenario 2 ditunjukkan pada Tabel 4.7.

**Tabel 4.7** Hasil Uji White Noise dan Normalitas pada Residual Skenario 2

Lag ke-	Uji <i>White noise</i>			Uji Normalitas
	$\chi^2$	Df	<i>p</i> -value	<i>p</i> -value
6	4.84	4	0.3043	D=0,022392 <i>p</i> -value=> 0,1500
12	7.81	10	0.6471	
18	12.15	16	0.7339	
24	15.84	22	0.8239	
30	19.59	28	0.8791	
36	23.28	34	0.9172	
42	24.45	40	0.9749	
48	38.32	46	0.7821	

Dapat diketahui dari Tabel 4.7 bahwa residual sudah memenuhi asumsi *white noise* dan residual telah berdistribusi normal karena memiliki nilai *p*-value yang lebih dari  $\alpha$  (0,05). Sehingga model persamaan data simulasi skenario 2 untuk jam 20:00 ( $Y_{40,t}$ ) dapat ditulis seperti berikut:


$$\begin{aligned}
Y_{40,t} = & 0,32t + 3528,9D_{1,t}^W + 3543,9D_{2,t}^W + 3554,7D_{3,t}^W + 3541,7D_{4,t}^W \\
& + 3484,5D_{5,t}^W + 3428,7D_{6,t}^W + 3332,3D_{7,t}^W - 452,38D_{1,t}^V - 280,86D_{2,t}^V \\
& - 306,17D_{3,t}^V - 242,28D_{4,t}^V - 136,59D_{5,t}^V - 246,42D_{6,t}^V - 14,88D_{7,t}^V \\
& - 33,33D_{8,t}^V - 84,53D_{9,t}^V - 240,81D_{10,t}^V - 351D_{11,t}^V - 344,26D_{12,t}^V \\
& - 652,66D_{13,t}^V - 881,52D_{14,t}^V - 682,71D_{15,t}^V - 658,11D_{16,t}^V - 574,49D_{17,t}^V \\
& - 411,20D_{18,t}^V - 147,78D_{19,t}^V - 198,66D_{20,t}^V - 99,44D_{21,t}^V + \frac{1-0,38B}{1-0,64B}a_t
\end{aligned}$$

Dengan cara yang sama dilakukan permodelan ARIMAX untuk data simulasi skenario 2 untuk jam 08:00, 12:00, 16:00, 20:00, 24:00. Berdasarkan pendugaan model pada beberapa waktu didapatkan model terbaik dengan hasil pada Tabel 4.8.


**Tabel 4.8** Komponen ARIMA pada Model ARIMAX untuk Data Simulasi Skenario 2 Masing-masing waktu

Jam	Model	Residual <i>White noise</i>	Residual Berdistribusi Normal
04:00	ARIMA (2,0,0)	Ya	Ya
08:00	ARIMA (2,0,2)	Ya	Ya
12:00	ARIMA (0,0,4)	Ya	Ya
16:00	ARIMA (1,0,[2])	Ya	Ya
20:00	ARIMA (1,0,1)	Ya	Ya
24:00	ARIMA ([2],0,1)	Ya	Ya

Berdasarkan model persamaan pada Tabel 4.8 dilakukan perbandingan data aktual dan ramalan, yang ditunjukkan pada Gambar 4.11 sebagai berikut:




**Gambar 4.11** Perbandingan Data Aktual dan Ramalan Bebearapa Waktu untuk Simulasi Skenario 2 dengan Model ARIMAX



**Gambar 4.11** Perbandingan Data Aktual dan Ramalan Beberapa Waktu untuk Simulasi Skenario 2 dengan Model ARIMAX (lanjutan)

Pada Gambar 4.11 menunjukkan bahwa dengan model ARIMAX yang diterapkan pada data simulasi skenario 2. Dapat dilihat hasil peramalan dengan ARIMAX belum mampu menangkap pola nonlinear pada data simulasi skenario 2 baik untuk data *training* maupun untuk data *testing*.

Analisis selanjutnya akan dilakukan permodelan dengan *deep neural network* pada data simulasi skenario 2. Pada penelitian ini akan digunakan dua *hidden layer* dengan masing-masing *hidden layer* merupakan kombinasi 1 sampai dengan 5 neuron dan digunakan fungsi aktivasi sigmoid untuk *hidden layer* dan fungsi aktivasi identitas untuk *output layer*. Pada penelitian ini juga akan dilakukan 10 replikasi. Sebelum dilakukan analisis, data dilakukan normalisasi terlebih dahulu. Input yang digunakan pada model DNN adalah lag PACF data yang signifikan dan komponen ARIMAX yang terdiri dari komponen tren, komponen musiman harian dan komponen variasi kalender. Plot PACF untuk data simulasi skenario 2 untuk jam 20:00 akan ditampilkan pada Gambar 4.12.



**Gambar 4.12** Plot PACF untuk Data Simulasi Skenario 2 pada jam 20:00

Berdasarkan Gambar 4.12, input yang akan digunakan pada model DNN adalah lag 1, 2, 4-9, 11-13, 15, 18-22, 26-29, 35, 42, dan 47. Komponen ARIMAX yang juga masuk ke dalam input pada DNN antara lain  $T$ ,  $D_1^W$ ,  $D_2^W$ ,  $D_3^W$ ,  $D_4^W$ ,  $D_5^W$ ,  $D_6^W$ ,  $D_7^W$ ,  $D_1^V$ ,  $D_2^V$ ,  $D_3^V$ ,  $D_4^V$ ,  $D_5^V$ ,  $D_6^V$ ,  $D_7^V$ ,  $D_8^V$ ,  $D_9^V$ ,  $D_{10}^V$ ,  $D_{11}^V$ ,  $D_{12}^V$ ,  $D_{13}^V$ ,  $D_{14}^V$ ,  $D_{15}^V$ ,  $D_{16}^V$ ,  $D_{17}^V$ ,  $D_{18}^V$ ,  $D_{19}^V$ ,  $D_{20}^V$ , dan  $D_{21}^V$ . Selanjutnya dilakukan uji nonlinieritas dengan menggunakan Uji White yang didapatkan hasil bahwa data memiliki hubungan yang nonlinear. Sehingga didapatkan arsitektur

DNN optimum adalah 1 neuron pada *hidden layer* 1 dan 3 neuron pada *hidden layer* 2 yang akan ditampilkan pada Gambar 4.13. Sedangkan persamaan model DNN untuk dapat skenario 2 pada jam 20:00 ( $Y_{40,t}^*$ ) akan ditampilkan sebagai berikut:

$$Y_{40,t}^* = 0,27 + 1,82fh_1^2(.) - 0,38fh_2^2(.) + 0,52fh_3^2(.)$$

dengan

$$fh_1^2(.) = (1 + \exp(-(-1,38 - 56,95fh_1^1(.))))^{-1}$$


$$fh_2^2(.) = (1 + \exp(-(-0,91 - 12,57fh_2^1(.))))^{-1}$$

$$fh_3^2(.) = (1 + \exp(-(3,38 - 1,82fh_3^1(.))))^{-1}$$

dengan

$$fh_1^1 = (1 + \exp(-(1,21 - 1,58Z_{t-1} - 0,74Z_{t-2} + \dots - 0,25D_{21}^v))))^{-1}$$

dengan  $Y_{40,t}^*$  merupakan hasil normalisasi dari  $Y_{40,t}$




**Gambar 4.13** Arsitektur DNN untuk Data Simulasi Skenario 2 pada jam 20:00

Berikut merupakan arsitektur model DNN untuk masing-masing waktu:


**Tabel 4.9** Arsitektur untuk Permodelan DNN pada Skenario 2

Jam	Input	Jumlah neuron	
		<i>Hidden 1</i>	<i>Hidden 2</i>
04:00	1, 2, 4-7, 11-14, 17, 19-21, 26, 28, 32, 35, 41, 47	1	2
08:00	1-9, 12, 13, 15, 16, 20-23, 27-29, 35, 42	1	4
12:00	1, 2, 4-9, 11-15, 19-23, 28, 29, 35, 42	3	1
16:00	1-3, 6-9, 11, 13-16, 20-23, 26-29, 35, 36, 38, 42, 47	1	1
20:00	1, 2, 4-9, 11-13, 15, 18-22, 26-29, 35, 42, 47	1	3
24:00	1-7, 11-14, 19,-21, 27, 28, 35, 36, 42	4	3

Berdasarkan arsitektur optimum pada Tabel 4.9 dilakukan perbandingan data aktual dan ramalan, yang ditunjukkan pada Gambar 4.14 sebagai berikut:



**Gambar 4.14** Perbandingan Data Aktual Skenario 2 dan Ramalan dengan menggunakan model DNN



**Gambar 4.14** Perbandingan Data Aktual Skenario 2 dan Ramalan dengan menggunakan model DNN (lanjutan)

Pada Gambar 4.14 menunjukkan bahwa dengan model DNN yang diterapkan pada data simulasi skenario 2 belum cukup baik dalam meramalkan pada data *training* dan data *testing*. Hal ini dapat dilihat dari hasil ramalan belum mengikuti pola data aktual pada data *training* dan data *testing*.

Analisis selanjutnya yang akan dilakukan untuk data simulasi skenario 2 adalah permodelan dengan hibrida ARIMAX-DNN. Data yang digunakan untuk permodelan hibrida ARIMAX-



DNN merupakan residual dari model ARIMAX yang telah dilakukan sebelumnya dan kemudahan data residual tersebut dilakukan normalisasi. Input yang digunakan pada model DNN adalah lag signifikan dari komponen ARIMAX dan input yang digunakan pada ARIMAX yang diantaranya komponen tren (T), komponen musiman harian ( $D_2^W, D_3^W, D_4^W, D_5^W, D_6^W, D_7^W$ ), dan komponen kalender variasi ( $D_1^W, D_1^V, D_2^V, D_3^V, D_4^V, D_5^V, D_6^V, D_7^V, D_8^V, D_9^V, D_{10}^V, D_{11}^V, D_{12}^V, D_{13}^V, D_{14}^V, D_{15}^V, D_{16}^V, D_{17}^V, D_{18}^V, D_{19}^V, D_{20}^V, dan D_{21}^V$ ). Pada jam 20:00 input yang digunakan adalah 1 karena model ARIMA untuk komponen ARIMAX adalah AR(1). Pada penelitian ini akan digunakan dua *hidden layer* dengan masing-masing *hidden layer* merupakan kombinasi 1 sampai dengan 5 neuron dan digunakan fungsi aktivasi sigmoid untuk *hidden layer* dan fungsi aktivasi linear untuk *output layer*. Pada penelitian ini juga akan dilakukan 10 replikasi. Sehingga didapatkan arsitektur DNN optimum untuk data skenario 2 jam 20:00 adalah 1 neuron pada *hidden layer* 1 dan 1 neuron pada *hidden layer* 2 yang akan ditampilkan pada Gambar 4.15. Sedangkan persamaan model DNN untuk data sekanario 2 pada jam 20:00 ( $\hat{Y}_{40,t}$ ) akan ditampilkan sebagai berikut:

$$\hat{Y}_{40,t} = \hat{L}_t + \hat{N}_t \text{ dengan } \hat{N}_t \text{ normalized dari } \hat{N}_t^*$$

dimana

$$\begin{aligned} \hat{L}_t = & 0,32t + 3528,9D_{1,t}^W + 3543,9D_{2,t}^W + 3554,7D_{3,t}^W + 3541,7D_{4,t}^W + 3484,5D_{5,t}^W + \\ & 3428,7D_{6,t}^W + 3332,3D_{7,t}^W - 452,38D_{1,t}^V - 280,86D_{2,t}^V - 306,17D_{3,t}^V - 242,28D_{4,t}^V - \\ & 136,59D_{5,t}^V - 246,42D_{6,t}^V - 14,88D_{7,t}^V - 33,33D_{8,t}^V - 84,53D_{9,t}^V - 240,81D_{10,t}^V - \\ & 351D_{11,t}^V - 344,26D_{12,t}^V - 652,66D_{13,t}^V - 881,52D_{14,t}^V - 682,71D_{15,t}^V - 658,11D_{16,t}^V - \\ & 574,49D_{17,t}^V - 411,20D_{18,t}^V - 147,78D_{19,t}^V - 198,66D_{20,t}^V - 99,44D_{21,t}^V + \frac{1-0,38B}{1-0,64B}a_t \end{aligned}$$

$$\hat{N}_t^* = 0,93 - 6,78fh_1^2(.)$$

dengan

$$\begin{aligned} fh_1^2(.) = & (1 + \exp(-(-0,78 - 0,60fh_1^1(.) - 0,49fh_2^1(.) - 1,40fh_3^1(.) - 25,52fh_4^1(.) \\ & - 0,75fh_5^1(.))))^{-1} \end{aligned}$$

dengan


$$fh_1^1(.) = (1 + \exp(-(-10,34 + 15,74Z_{t-1} - 1,45Z_{t-2} + \dots - 2,45D_{21}^v)))^{-1}$$

$$fh_2^1(.) = (1 + \exp(-(-10,34 - 67,67Z_{t-1} + 0,21Z_{t-2} + \dots - 773,54D_{21}^v)))^{-1}$$

$$fh_3^1(.) = (1 + \exp(-(-2,02 + 3,86Z_{t-1} - 0,01Z_{t-2} + \dots + 5,21D_{21}^v)))^{-1}$$

$$fh_4^1(.) = (1 + \exp(-(-1,55 + 11,42Z_{t-1} - 0,79Z_{t-2} + \dots + 30,53D_{21}^v)))^{-1}$$

$$fh_5^1(.) = (1 + \exp(-(-20,30 - 67,79Z_{t-1} + 0,025Z_{t-2} + \dots + 13,17D_{21}^v)))^{-1}$$




**Gambar 4.15** Arsitektur DNN pada Model Hibrida ARIMAX-DNN untuk Data Simulasi Skenario 2 pada jam 20:00


Dengan cara yang sama, dilakukan permodelan hibrida ARIMAX-DNN untuk beberapa jam lain. Berikut merupakan arsitektur model hibrida ARIMAX-DNN untuk masing-masing jam:

**Tabel 4.10** Arsitektur Permodelan Hibrida ARIMAX-DNN pada Skenario 2

Jam	Input	Arsitektur	
		Hidden 1	Hidden 2
04:00	1,2	5	3
08:00	1,2	5	2
12:00	1	5	1
16:00	1	5	4
20:00	1	5	1
24:00	2	1	2

Berdasarkan arsitektur optimum pada Tabel 4.10 dilakukan perbandingan data aktual dan ramalan, yang ditunjukkan pada Gambar 4.16 sebagai berikut:

**Gambar 4.16** Perbandingan Data Aktual Skenario 2 dan Ramalan dengan Menggunakan Model Hibrida ARIMAX-DNN



**Gambar 4.16** Perbandingan Data Aktual Skenario 2 dan Ramalan dengan Menggunakan Model Hibrida ARIMAX-DNN (lanjutan)

Pada Gambar 4.16 menunjukkan bahwa dengan model Hibrida ARIMAX-DNN yang diterapkan pada data simulasi skenario 2 belum cukup baik dalam meramalkan pada data *training* dan data *testing*. Hal ini dapat dilihat dari hasil ramalan belum mengikuti pola data aktual pada data *training* dan data *testing*.

#### 4.1.2 Perbandingan Hasil Simulasi

Berikut merupakan perbandingan kebaikan model data *training* dan data *testing* selama 365 hari kedepan pada ketiga model untuk keseluruhan skenario yang ditampilkan pada Tabel 4.11 dan Tabel 4.12.


**Tabel 4.11** Perbandingan RMSEP untuk Masing-masing Skenario

Skenario	Jam	ARIMAX		DNN		ARIMAX-DNN	
		Data <i>Training</i>	Data <i>Testing</i>	Data <i>Training</i>	Data <i>Testing</i>	Data <i>Training</i>	Data <i>Testing</i>
1	04:00	29,60	42,36	35,77	48,95	29,02	<b>42,21</b>
	08:00	29,99	44,51	37,81	45,29	29,87	<b>44,30</b>
	12:00	29,27	44,86	39,35	48,10	29,93	<b>44,84</b>
	16:00	29,05	43,33	37,77	47,16	28,74	<b>43,29</b>
	20:00	29,82	37,92	35,46	41,03	29,33	<b>37,64</b>
	24:00	28,87	41,74	34,38	45,13	29,44	<b>41,63</b>
2	04:00	90,60	96,42	91,60	97,44	88,24	<b>95,94</b>
	08:00	90,97	100,55	92,40	100,56	90,20	<b>100,04</b>
	12:00	91,63	102,81	92,59	103,45	90,54	<b>102,42</b>
	16:00	91,00	99,05	92,77	103,01	89,76	<b>98,92</b>
	20:00	94,60	101,56	93,51	<b>100,01</b>	93,10	100,87
	24:00	92,00	99,06	88,33	103,86	91,93	<b>98,71</b>


**Tabel 4.12** Perbandingan sMAPE untuk Masing-masing Skenario

Skenario	Jam	ARIMAX		DNN		ARIMAX-DNN	
		Data <i>Training</i>	Data <i>Testing</i>	Data <i>Training</i>	Data <i>Testing</i>	Data <i>Training</i>	Data <i>Testing</i>
1	04:00	0,87%	1,15%	1,03%	1,29%	0,84%	<b>1,15%</b>
	08:00	0,85%	1,17%	1,07%	1,17%	0,84%	<b>1,16%</b>
	12:00	0,81%	1,10%	1,03%	1,16%	0,81%	<b>1,10%</b>
	16:00	0,76%	1,03%	0,97%	1,12%	0,74%	<b>1,03%</b>
	20:00	0,65%	0,77%	0,75%	0,83%	0,63%	<b>0,77%</b>
	24:00	0,83%	1,03%	0,93%	1,10%	0,81%	<b>1,03%</b>
2	04:00	2,76%	2,61%	2,73%	2,63%	2,63%	<b>2,58%</b>
	08:00	2,66%	2,57%	2,61%	2,57%	2,61%	<b>2,56%</b>
	12:00	2,55%	2,52%	2,48%	2,54%	2,48%	<b>2,51%</b>
	16:00	2,44%	2,34%	2,43%	2,45%	2,37%	<b>2,33%</b>
	20:00	2,10%	2,05%	2,06%	<b>1,98%</b>	2,05%	2,04%
	24:00	2,65%	2,51%	2,44%	2,63%	2,65%	<b>2,50%</b>

Berdasarkan Tabel 4.11 dan Tabel 4.12, Perbandingan RMSE dan sMAPE dapat divisualisasikan pada Gambar 4.17 dan Gambar 4.18.



**Gambar 4.17** Perbandingan RMSEP untuk Masing-masing Skenario



**Gambar 4.18** Perbandingan sMAPE untuk Masing-masing Skenario

Pada Gambar 4.17 dan Gambar 4.18 menunjukkan pada skenario 1 model Hibrida ARIMAX-DNN merupakan model terbaik yang dapat digunakan untuk peramalan dan model terbaik

kedua adalah ARIMAX. Hal ini disebabkan karena pada skenario 1 mengandung pola linear sehingga model ARIMAX lebih baik dibandingkan dengan model DNN. Sedangkan pada skenario 2 yang memiliki pola non linear, secara umum model hibrida ARIMAX-DNN merupakan model terbaik kecuali pada series jam 20:00 yang model terbaiknya adalah model DNN. Untuk model terbaik kedua untuk data skenario 2 adalah pada model ARIMAX yang lebih mampu menghasilkan akurasi yang lebih baik dibandingkan model DNN. Hal ini sama seperti pada penelitian yang dilakukan oleh Makridaris dkk (2018). Penelitian tersebut melakukan perbandingan akurasi dari 8 metode statistika tradisional dan 10 metode *Machine Learning*. Pada penelitian tersebut didapatkan hasil bahwa metode statistika tradisional lebih baik dibandingkan dengan metode *Machine Learning*. Selanjutnya dilakukan perhitungan akurasi dari berbagai periode *horizon* yang terdiri dari *short horizon* (1-7 hari), *medium horizon* (1-181 hari), dan *long horizon* (1-365 hari). Perhitungan berbagai periode *horizon* untuk skenario 1 dan skenario 2 ditampilkan pada Lampiran 7. Berdasarkan perhitungan RMSEP untuk berbagai periode *horizon* didapatkan model terbaik untuk masing-masing skenario pada Tabel 4.13.

**Tabel 4.13** Metode Terbaik untuk Masing-masing Skenario

Skenario	Jam	Short	Medium	Long
1 (noise linear)	04:00	DNN	Hibrida	Hibrida
	08:00	DNN	Hibrida	Hibrida
	12:00	ARIMAX	Hibrida	Hibrida
	16:00	ARIMAX	Hibrida	Hibrida
	20:00	ARIMAX	Hibrida	Hibrida
	24:00	ARIMAX	ARIMAX	DNN
2 (noise nonlinear)	04:00	Hibrida	Hibrida	Hibrida
	08:00	DNN	Hibrida	Hibrida
	12:00	Hibrida	Hibrida	Hibrida
	16:00	ARIMAX	Hibrida	Hibrida
	20:00	Hibrida	ARIMAX	DNN
	24:00	ARIMAX	Hibrida	Hibrida

Berdasarkan perhitungan akurasi untuk beberapa horizon diketahui bahwa pada skenario 1 model ARIMAX merupakan model terbaik pada *horizon short* dan model Hibrida ARIMAX-DNN merupakan model terbaik pada *horizon medium* dan *long*. Sedangkan pada skenario 2 model Hibrida ARIMX-DNN merupakan model terbaik pada *horizon short, medium, dan long*.


#### 4.2 Karakteristik Data Beban Listrik Per Setengah Jam

Pada penelitian ini akan digunakan data beban listrik per setengah jam di wilayah Jateng dan DIY. Data beban yang digunakan ini merupakan jumlah konsumsi untuk sektor rumah tangga, industri, komersial dan fasilitas umum. Pola dari beban listrik untuk setiap setengah jam dari tahun 2013 hingga 2017 dapat ditampilkan pada Gambar 4.19.



**Gambar 4.19** Plot time series Beban Listrik Per Setengah Jam Periode 2013-2017





**Gambar 4.19** Plot *time series* Beban Listrik Per Setengah Jam Periode 2013-2017 (lanjutan)

Berdasarkan Gambar 4.19, dapat dilihat untuk data beban listrik per setengah jam memiliki pola tren naik serta data memiliki outlier. Hal ini dapat terlihat dari adanya data beban yang jauh lebih rendah jika dibandingkan dengan beban listrik lainnya. Pada jam 08:30 hingga 17:00 memiliki keragaman yang lebih tinggi dibandingkan beban pada jam lainnya. Hal ini menunjukkan adanya keragaman aktifitas yang terjadi pada siang hari. Berikut merupakan tabel statistika deskriptif data beban listrik Jateng-DIY per setengah jam:


**Tabel 4.14** Statistika Deskriptif data Beban Listrik Jateng-DIY per Setengah Jam

Jam	Mean	Standar Deviasi	Jam	Mean	Standar Deviasi
00:30	2574,7	209,8	12:30	2729,4	318,1
01:00	2535,4	207,5	13:00	2795,9	339,4
01:30	2502,8	206,4	13:30	2872,6	365,8
02:00	2473,6	205,2	14:00	2857,3	362,5
02:30	2450,5	206,0	14:30	2839,1	357,1
03:00	2439,8	209,9	15:00	2824,8	349,9
03:30	2448,9	223,4	15:30	2842,7	346,3
04:00	2483,8	234,1	16:00	2846,8	329,7
04:30	2578,0	229,7	16:30	2862,1	315,9
05:00	2700,3	224,6	17:00	2931,7	307,4
05:30	2786,7	229,9	17:30	3147,6	314,6
06:00	2694,8	236,1	18:00	3431,4	304,1
06:30	2561,5	234,3	18:30	3508,8	273,0
07:00	2487,2	236,3	19:00	3514,1	266,1
07:30	2544,0	265,0	19:30	3492,7	262,9
08:00	2615,6	289,9	20:00	3460,5	257,1
08:30	2700,6	316,3	20:30	3404,0	252,4
09:00	2741,5	327,6	21:00	3295,9	245,2
09:30	2770,0	333,5	21:30	3153,7	237,3
10:00	2795,9	337,3	22:00	3006,0	229,9

**Tabel 4.14** Statistika Deskriptif data Beban Listrik Jateng-DIY per Setengah Jam (lanjutan)

Jam	Mean	Standar Deviasi	Jam	Mean	Standar Deviasi
10:30	2823,7	344,3	22:30	2888,2	225,5
11:00	2841,9	351,3	23:00	2782,5	220,7
11:30	2834,1	347,2	23:30	2704,2	217,8
12:00	2751,1	321,6	00:00	2630,7	213,3


Berikut merupakan pola pemakaian listrik per setengah jam Jateng-DIY periode 2013 hingga 2017:



**Gambar 4.20** Pola Pemakaian Listrik per Setengah Jam di Jateng-DIY periode 2013-2017


Gambar 4.20 menunjukkan pola karakteristik pemakaian listrik di Jateng-DIY. Pada jam 04:00 hingga 05:30 terjadi

kenaikan pemakaian listrik. Hal ini dikarenakan konsumen rumah tangga mulai melakukan aktivitas pagi. Selanjutnya pemakaian listrik turun hingga jam 07:00 dan naik kembali pada jam 08:00 hingga jam 11:30. Kenaikan konsumsi listrik ini terjadi disebabkan konsumen industri, perkantoran, pendidikan, dan instansi lain mulai melakukan aktifitas. Kemudian konsumsi listrik turun setelah jam 11:30 hingga 12:30 dimana waktu tersebut merupakan waktu istirahat kerja. Pada jam 13:00 hingga 16:30 pemakaian listrik sama seperti waktu sebelum istirahat. Pada jam 17:00 hingga jam 19:00 konsumsi listrik naik cukup drastis dan pada jam 19:00 merupakan waktu terjadinya beban puncak. Selanjutnya pada jam 19:30 hingga jam 03:00 konsumsi listrik mulai mengalami penurunan. Pola konsumsi pemakaian listrik harian di Jateng-DIY ditunjukkan pada Gambar 4.21.



**Gambar 4.21** Pola Pemakaian Listrik Harian di Jateng-DIY periode 2013-2017

Berdasarkan Gambar 4.21 dapat dilihat terdapat perbedaan konsumsi listrik pada hari kerja dan hari libur kerja. Pemakaian listrik pada hari Sabtu dan Minggu lebih rendah dibandingkan dengan hari kerja yaitu Senin hingga Jumat. Hal ini menunjukkan bahwa pemakaian listrik untuk industri dan kantor berpengaruh terhadap konsumsi listrik di wilayah Jateng dan DIY. Sehingga pada hari libur kerja pada hari Sabtu dan Minggu konsumsi listrik mengalami penurunan. Selanjutnya dibentuk *scatterplot* untuk melihat apakah data beban yang mengikuti pola linear atau pola nonlinear.



**Gambar 4.22** Scatterplot antara Data Beban Listrik ( $Y_t$ ) dan Lag Data Beban Listrik ( $Y_{t-1}$ )

Berdasarkan Gambar 4.22 dapat dilihat secara keseluruhan antara data beban listrik dan lag 1 beban listrik memiliki pola yang linear.

### 4.3 Permodelan Data Beban Listrik Per Setengah Jam Wilayah Jawa Tengah dan DIY

#### 4.3.1 Permodelan dengan ARIMAX

Tahap ARIMAX untuk data beban listrik sama seperti tahap ARIMAX pada data simulasi. Langkah pertama untuk permodelan ARIMAX estimasi parameter regresi *time series*. Estimasi parameter regresi *time series* untuk data beban listrik jam 20:00 dapat dilihat pada Tabel 4.15 berikut:

**Tabel 4.15** Estimasi Parameter Regresi *Time Series* Data Beban Listrik 20:00

Variabel	Estimasi	SE	<i>t</i> -value	<i>p</i> -value
$\phi_1$	0,30294	0,02658	11,4	<0,0001
$\phi_2$	0,15602	0,02736	5,7	<0,0001
$\phi_3$	0,09115	0,02687	3,39	0,0007
$\phi_6$	0,05529	0,02647	2,09	0,0369
$\phi_7$	0,07609	0,02612	2,91	0,0036
$\phi_{18}$	0,08379	0,02385	3,51	0,0005
$\phi_{46}$	0,06961	0,02341	2,97	0,003
T	0,43162	0,03092	13,96	<0,0001
$D_1^W$	3141,4	26,50327	118,53	<0,0001
$D_2^W$	3147,1	26,46428	118,92	<0,0001
$D_3^W$	3150,4	26,48226	118,96	<0,0001
$D_4^W$	3144,2	26,51886	118,57	<0,0001
$D_5^W$	3132,1	26,52694	118,07	<0,0001
$D_6^W$	3034,8	26,50596	114,49	<0,0001
$D_7^W$	2951,7	26,49987	111,39	<0,0001
$D_1^V$	-341,483	44,18369	-7,73	<0,0001
$D_2^V$	-241,515	39,27188	-6,15	<0,0001
$D_3^V$	-268,844	50,45285	-5,33	<0,0001
$D_4^V$	-179,906	43,655	-4,12	<0,0001
$D_5^V$	-231,631	43,9893	-5,27	<0,0001
$D_6^V$	-270,338	61,78005	-4,38	<0,0001
$D_7^V$	-121,458	44,07528	-2,76	0,0059
$D_8^V$	-106,315	50,61953	-2,1	0,0359

**Tabel 4.15** Estimasi Parameter Regresi *Time Series* Data Beban Listrik 20:00 (lanjutan)

Variabel	Estimasi	SE	<i>t</i> -value	<i>p</i> -value
$D_9^V$	-131,766	43,90253	-3	0,0027
$D_{10}^V$	-356,369	50,52141	-7,05	<0,0001
$D_{11}^V$	-140,91	46,10804	-3,06	0,0023
$D_{12}^V$	-359,328	47,73028	-7,53	<0,0001
$D_{13}^V$	-624,261	48,65003	-12,83	<0,0001
$D_{14}^V$	-826,877	49,27362	-16,78	<0,0001
$D_{15}^V$	-745,847	49,25615	-15,14	<0,0001
$D_{16}^V$	-617,619	48,62655	-12,7	<0,0001
$D_{17}^V$	-519,132	47,66307	-10,89	<0,0001
$D_{18}^V$	-326,082	46,07654	-7,08	<0,0001
$D_{19}^V$	-324,285	50,55582	-6,41	<0,0001
$D_{20}^V$	-263,924	50,54979	-5,22	<0,0001
$D_{21}^V$	-246,619	50,59916	-4,87	<0,0001

Pada Tabel 4.15 dapat dilihat semua variabel input pada model ARIMAX yang memiliki *p*-value yang lebih dari  $\alpha$  (0,05). Artinya semua variabel berpengaruh signifikan terhadap data beban listrik pada jam 20:00. Selanjutnya dilakukan pengujian asumsi *white noise* dan berdistribusi normal pada residual. Apabila asumsi residual belum terpenuhi, maka perlu dilakukan permodelan dengan ARIMA. Setelah dilakukan uji asumsi residual pada data, didapatkan model untuk residual regresi *time series* adalah ARIMA([1,2,3,6,7,18,46],0,0). Selanjutnya, dilakukan pengujian asumsi pada residual model ARIMA yaitu residual *white noise* dan berdistribusi normal. Hasil pengujian asumsi pada residual ARIMA pada data beban listrik jam 20:00 ditunjukkan pada Tabel 4.16.

**Tabel 4.16** Hasil Uji White Noise dan Normalitas pada Residual

Uji <i>White noise</i>				Uji Normalitas
Lag ke-	$\chi^2$	df	<i>p</i> -value	<i>p</i> -value
6	.	0	.	D=0,132981 P-value=<0,010
12	10,04	5	0,0741	
18	14,37	11	0,213	
24	26,78	17	0,0614	


**Tabel 4.16** Hasil Uji White Noise dan Normalitas pada Residual (lanjutan)

Uji White noise				Uji Normalitas
Lag ke-	$\chi^2$	df	p-value	p-value
30	28,67	23	0,1915	
36	35,53	29	0,1878	
42	38,43	35	0,3171	
48	40,39	41	0,4974	

Dapat diketahui dari Tabel 4.16 bahwa residual sudah memenuhi asumsi *white noise* dikarenakan semua *p-value* memiliki nilai yang lebih dari  $\alpha$  (0,05) dan residual tidak berdistribusi normal karena memiliki nilai *p-value* yang lebih dari  $\alpha$  (0,05). Hal ini diduga residual data beban listrik pada jam 20:00 masih memiliki data *outlier* yang dapat dilihat pada Lampiran 9 sehingga permodelan dengan menggunakan ARIMAX belum mampu mengatasi pola tersebut. Model persamaan data beban listrik untuk jam 20:00 ( $Y_{40,t}$ ) sebagai berikut:

$$\begin{aligned}
Y_{40,t} = & 0,43t + 3141,4D_{1,t}^W + 3147,1D_{2,t}^W + 3150,4D_{3,t}^W + 3144,2D_{4,t}^W \\
& + 3132,1D_{5,t}^W + 3034,8D_{6,t}^W + 2951,7D_{7,t}^W - 341,48D_{1,t}^V - 241,52D_{2,t}^V \\
& - 268,84D_{3,t}^V - 179,91D_{4,t}^V - 231,63D_{5,t}^V - 270,34D_{6,t}^V - 121,46D_{7,t}^V \\
& - 106,32D_{8,t}^V - 131,77D_{9,t}^V - 356,37D_{10,t}^V - 140,91D_{11,t}^V - 359,33D_{12,t}^V \\
& - 624,26D_{13,t}^V - 826,88D_{14,t}^V - 745,85D_{15,t}^V + 617,62D_{16,t}^V - 519,13D_{17,t}^V \\
& - 326,08D_{18,t}^V + 324,28D_{19,t}^V + 263,92D_{20,t}^V + 246,62D_{21,t}^V \\
& + \frac{1}{(1-0,30B-0,15B^2-0,09B^3-0,05B^6-0,07B^7-0,08B^{18}-0,07B^{46})} a_t
\end{aligned}$$

Berdasarkan model persamaan yang telah ditentukan, dilakukan perbandingan data aktual dan ramalan, yang ditunjukkan pada Gambar 4.23.



**Gambar 4.23** Perbandingan Data Beban Listrik jam 20:00 dan Ramalan dengan Menggunakan ARIMAX

Dengan cara yang sama, dilakukan permodelan ARIMAX untuk data beban listrik per setengah jam. Berdasarkan pendugaan model pada beberapa waktu didapatkan model terbaik ARIMA dengan hasil pada Tabel 4.17.

**Tabel 4.17** Komponen ARIMA pada Model ARIMAX Data Beban Listrik untuk Masing-Masing Waktu

Jam	Model ARIMA	White Noise	Distribusi Normal
00:30	[1,3,4,7,18],0,0	Ya	Tidak
01:00	[1,3,7],0,0	Ya	Tidak
01:30	[1,3,7],0,0	Ya	Tidak
02:00	[1,3,7],0,0	Ya	Tidak
02:30	[1,2,3],0,0	Ya	Tidak
03:00	[1,3,7],0,0	Ya	Tidak
03:30	[1,3],0,0	Ya	Tidak
04:00	[1,3],0,0	Ya	Tidak
04:30	[1,3],0,0	Ya	Tidak
05:00	[1,3,7],0,0	Ya	Tidak
05:30	[1,3,7],0,0	Ya	Tidak
06:00	[1,2,7],0,0	Ya	Tidak
06:30	[1,2,5,7],0,0	Ya	Tidak
07:00	[1,2,5,7],0,0	Ya	Tidak
07:30	[1,2,4,6,7],0,0	Ya	Tidak
08:00	[1,2,4,7,14],0,0	Ya	Tidak
08:30	[1,2,4,7],0,0	Ya	Tidak
09:00	[1,2,4,7],0,0	Ya	Tidak
09:30	[1,2,4,7,14,19,20],0,0	Ya	Tidak
10:00	[1,2,4,7,19,20],0,0	Ya	Tidak
10:30	[1,2,4,7,14,19,20],0,0	Ya	Tidak




**Tabel 4.17** Komponen ARIMA pada Model ARIMAX Data Beban Listrik untuk Masing-Masing Waktu (lanjutan)

Jam	Model ARIMA	White Noise	Distribusi Normal
11:00	[1,2,4,7,9,14],0,0	Ya	Tidak
11:30	[1,2,4,7,14],0,0	Ya	Tidak
12:00	[1,2,7,14],0,0	Ya	Tidak
12:30	[1,2,7,14],0,0	Ya	Tidak
13:00	[1,2,3,7,14],0,0	Ya	Tidak
13:30	[1,2,7,14],0,0	Ya	Tidak
14:00	[1,2,7,14],0,0	Ya	Tidak
14:30	[1,2,7,14],0,0	Ya	Tidak
15:00	[1,2,7,14],0,0	Ya	Tidak
15:30	[1,2,3,7,8],0,0	Ya	Tidak
16:00	[1,2,3,7,8],0,0	Ya	Tidak
16:30	[1,2,3,7],0,0	Ya	Tidak
17:00	[1,2,3,7,16],0,0	Ya	Tidak
17:30	[1,2,3,7,10],0,0	Tidak	Tidak
18:00	[1,2,3,7,10,18],0,0	Tidak	Tidak
18:30	[1,2,3,7,10,18,24],0,0	Ya	Tidak
19:00	[1,2,3,7,10,15,18],0,0	Ya	Tidak
19:30	[1,2,3,7,10,15],0,0	Ya	Tidak
20:00	[1,2,3,6,7,18,46],0,0	Ya	Tidak
20:30	[1,2,3,7,18],0,0	Ya	Tidak
21:00	[1,2,3,7,18],0,0	Ya	Tidak
21:30	[1,2,3,4,18],0,0	Ya	Tidak
22:00	[1,2,3,4,46],0,0	Ya	Tidak
22:30	[1,2,3,4,7],0,0	Ya	Tidak
23:00	[1,2,3,7],0,0	Ya	Tidak
23:30	[1,2,3,7],0,0	Ya	Tidak
24:00	[1,2,5,7],0,0	Ya	Tidak

#### 4.3.2 Permodelan dengan Deep Neural Network

Analisis selanjutnya akan dilakukan permodelan dengan *deep neural network* pada data beban listrik. Tahap pertama yang dilakukan adalah tahap *preprocessing data* dengan menormalisasi data beban listrik jam 20:00. Pada penelitian ini akan digunakan dua *hidden layer* dengan masing-masing *hidden layer* merupakan kombinasi 1 sampai dengan 5 neuron dan digunakan fungsi

aktivasi sigmoid untuk *hidden layer* dan fungsi aktivasi identitas untuk *output layer*. Pada penelitian ini juga akan dilakukan 10 replikasi. Input yang digunakan pada model DNN adalah lag PACF data yang signifikan dan komponen ARIMAX diantaranya komponen tren, komponen musiman, dan komponen kalender variasi. Plot PACF untuk data beban listrik jam 20:00 akan ditampilkan pada Gambar 4.24.



**Gambar 4.24** Plot PACF untuk Data Beban Listrik pada Jam 20:00

Berdasarkan Gambar 4.23, input yang akan digunakan pada model DNN adalah lag 1-9, 11-15, 18, 20-22, 27-29, 35, 36, 41, 42, dan 43. Komponen ARIMAX yang juga masuk ke dalam input pada DNN antara lain  $T$ ,  $D_1^W$ ,  $D_2^W$ ,  $D_3^W$ ,  $D_4^W$ ,  $D_5^W$ ,  $D_6^W$ ,  $D_7^W$ ,  $D_1^V$ ,  $D_2^V$ ,  $D_3^V$ ,  $D_4^V$ ,  $D_5^V$ ,  $D_6^V$ ,  $D_7^V$ ,  $D_8^V$ ,  $D_9^V$ ,  $D_{10}^V$ ,  $D_{11}^V$ ,  $D_{12}^V$ ,  $D_{13}^V$ ,  $D_{14}^V$ ,  $D_{15}^V$ ,  $D_{16}^V$ ,  $D_{17}^V$ ,  $D_{18}^V$ ,  $D_{19}^V$ ,  $D_{20}^V$ , dan  $D_{21}^V$ . Selanjutnya dilakukan uji nonlinieritas dengan menggunakan Uji White yang didapatkan hasil bahwa data memiliki hubungan yang linear. Sehingga didapatkan arsitektur DNN optimum adalah 5 neuron pada *hidden layer* 1 dan 5 neuron pada *hidden layer* 2 yang akan ditampilkan pada Gambar 4.25. Sedangkan persamaan model DNN akan ditampilkan sebagai berikut:

$$Y_{40,t}^* = 1,33 + 0,84 fh_1^2(.) - 0,73 fh_2^2(.) - 0,53 fh_3^2(.) - 0,91 fh_4^2(.) + 0,38 fh_5^2(.)$$

dengan

$$fh_1^2(.) = (1 + \exp(-(0,41 - 7,08 fh_1^1(.) + 41,77 fh_2^1(.) + 44,75 fh_3^1(.) + 0,23 fh_4^1(.) - 79,86 fh_5^1(.))))^{-1}$$

$$fh_2^2(.) = (1 + \exp(-(0,08 + 20,74 fh_1^1(.) - 0,35 fh_2^1(.) + 2,23 fh_3^1(.) - 0,31 fh_4^1(.) + 0,01 fh_5^1(.))))^{-1}$$

$$fh_3^2(.) = (1 + \exp(-(-0,49 - 1,35 fh_1^1(.) + 20,24 fh_2^1(.) - 1,82 fh_3^1(.) - 0,53 fh_4^1(.) + 1,05 fh_5^1(.))))^{-1}$$

$$fh_4^2(.) = (1 + \exp(-(9,73 + 80,34 fh_1^1(.) + 19,39 fh_2^1(.) - 0,61 fh_3^1(.) + 10,82 fh_4^1(.) - 35,91 fh_5^1(.))))^{-1}$$

$$fh_5^2(.) = (1 + \exp(-(6,79 + 6,78 fh_1^1(.) - 29,23 fh_2^1(.) + 12,63 fh_3^1(.) + 7,64 fh_4^1(.) - 2,58 fh_5^1(.))))^{-1}$$

dengan

$$fh_1^1(.) = (1 + \exp(-(1,67 + 0,51Z_{t-1} - 0,71Z_{t-2} + \dots + 173,37D_{21}^V))))^{-1}$$


$$fh_2^1(.) = (1 + \exp(-(-0,98 - 0,15Z_{t-1} - 0,66Z_{t-2} + \dots + 0,31D_{21}^V))))^{-1}$$

$$fh_3^1(.) = (1 + \exp(-(0,15 - 16,04Z_{t-1} + 2,96Z_{t-2} + \dots - 38,03D_{21}^V))))^{-1}$$

$$fh_4^1(.) = (1 + \exp(-(0,34 - 0,64Z_{t-1} - 0,09Z_{t-2} + \dots - 0,13D_{21}^V))))^{-1}$$


$$fh_5^1(.) = (1 + \exp(-(0,92 - 1,09Z_{t-1} + 1,39Z_{t-2} + \dots - 697,78D_{21}^V))))^{-1}$$

dengan  $Y_{40,t}^*$  merupakan hasil normalisasi dari  $Y_{40,t}$



**Gambar 4.25** Arsitektur DNN untuk Data Beban Listrik jam 20:00

Berdasarkan model persamaan yang telah ditentukan, dilakukan perbandingan data aktual dan ramalan, yang ditunjukkan pada Gambar 4.26 sebagai berikut:



**Gambar 4.26** Perbandingan Data Aktual Jam 20:00 dan Data Ramalan dengan menggunakan model DNN

Berikut merupakan arsitektur model DNN untuk masing-masing waktu:

**Tabel 4.18** Arsitektur untuk Permodelan DNN pada Data Beban Listrik

Jam	Input	Jumlah Neuron	
		Hidden 1	Hidden 2
00:30	1-8, 10-15, 18, 20-22, 21, 22, 26-30, 34-36, 41, 43	2	3
01:00	1-8, 11-15, 18, 20-22, 26-30, 34-36, 41, 43	1	1
01:30	1-8, 11-15, 17, 18, 20-22, 26-30, 34, 35, 36, 41, 43	4	3
02:00	1-8, 11-15, 17, 18, 20-22, 26-30, 34-36, 41, 43	2	3
02:30	1-8, 11-15, 18, 20, 22, 26, 28-30, 34-36, 41, 43	1	4
03:00	1, 3, 5-8, 10-13, 15, 18, 20, 22, 28-31, 33-36, 41, 43	2	1
03:30	1, 3-8, 11-13, 15, 20, 22, 26, 28-31, 34, 36, 41, 43	5	4
04:00	1, 3, 5-8, 10, 11-15, 18, 20, 22, 28-31, 33, 34, 36, 41, 43	3	4
04:30	1-6, 8, 10-13, 15, 17, 20, 22, 26, 28-31, 33-36, 41, 43	3	2
05:00	1, 3, 5-8, 10-15, 18-20, 22, 26-29, 35, 36, 41, 43	2	4

**Tabel 4.18** Arsitektur untuk Permodelan DNN pada Data Beban Listrik (lanjutan)

Jam	Input	Jumlah Neuron	
		Hidden 1	Hidden 2
05:30	1, 3,-8, 10-15, 20-22, 27-29, 36, 41, 43	3	1
06:00	1-8, 12-15, 17, 20-22, 28, 29, 36, 40-43	1	3
06:30	1-8, 12-15, 17, 20, 22, 23, 27-29, 36, 41-43	5	4
07:00	1, 3-8, 12-15, 17, 19-22, 27-30, 34, 36, 42, 43	3	2
07:30	1-8, 12-15, 17, 19-22, 28, 29, 35, 36, 42, 43	2	3
08:00	1-8, 12-15, 17, 19-22, 28, 29, 35, 36, 42, 43	2	3
08:30	1-8, 12-15, 17, 19-22, 28, 29, 35, 36, 42, 43	5	1
09:00	1-8, 12-15, 17, 19-22, 28, 29, 35, 36, 42, 43	4	5
09:30	1-9, 12-15, 17, 19, 21, 22, 28, 29, 34-36, 42, 43	4	3
10:00	1-9, 12-15, 17, 19, 21, 22, 28, 29, 34-36, 42, 43	5	1
10:30	1-9, 12-15, 19, 21, 22, 28, 29, 34-36, 42, 43	4	4
11:00	1-9, 12-15, 18, 19, 21, 22, 28, 29, 34-36, 42, 43	2	2
11:30	1-9, 12-16, 18, 19, 21-23, 28, 29, 35, 36, 42, 43	5	1
12:00	1-9, 12-16, 18, 19, 21-23, 28, 29, 35, 36, 42, 43	5	1
12:30	1-8, 12-15, 18, 19, 21, 22, 28, 29, 35, 36, 42, 43	3	4
13:00	1-9, 12-16, 18, 19, 21, 22, 28, 29, 35, 36, 42, 43	5	5

**Tabel 4.18** Arsitektur untuk Permodelan DNN pada Data Beban Listrik  
(lanjutan)

Jam	Input	Jumlah Neuron	
		Hidden 1	Hidden 2
13:30	1-9, 12-15, 18, 19, 21, 22, 28, 29, 35, 36, 42, 43	5	4
14:00	1-9, 12-15, 18, 20-22, 28, 29, 35, 36, 41-43	2	5
14:30	1-9, 12-15, 18, 20-22, 28, 29, 35, 36, 41-43	2	2
15:00	1-9, 12-15, 18, 20-22, 27-29, 35, 36, 41, 43	2	2
15:30	1-9, 11-15, 18-22, 27-29, 31, 34-36, 41-43	2	4
16:00	1-9, 11-15, 19-22, 27-29, 31, 34, 35, 36, 41, 43	3	1
16:30	1-9, 11-15, 19-22, 28, 29, 31, 32, 34-36, 41-43	5	3
17:00	1-9, 11, 12-15, 19, 21, 22, 28, 29, 32, 34-36, 42, 43	3	1
17:30	1-10, 12, 14, 15, 19, 21, 22, 28, 29, 34-36, 42, 43	4	3
18:00	1-9, 12-15, 18, 20-22, 27-29, 35, 36, 41-43	4	4
18:30	1-9, 12-15, 18, 20-22, 28, 29, 34-36, 42, 43	5	3
19:00	1-9, 12-15, 18, 20-22, 27-29, 35, 36, 41-43	2	4
19:30	1-9, 11-15, 18, 20-22, 27-29, 34-36, 42, 43	2	2
20:00	1-9, 11-15, 18, 20-22, 27-29, 35, 36, 41-43	5	5
20:30	1-9, 11-15, 18, 20-22, 27-29, 34-36, 41-43	3	1
21:00	1-9, 11-15, 18, 20-22, 28, 29, 34-36, 41-43, 46	1	2

**Tabel 4.18** Arsitektur untuk Permodelan DNN pada Data Beban Listrik (lanjutan)

Jam	Input	Jumlah Neuron	
		Hidden 1	Hidden 2
21:30	1-8, 11-15, 18, 20-22, 26, 28, 29, 31, 34-36, 42, 43, 46	3	1
22:00	1-8, 11-15, 18, 20-22, 26, 28, 29, 34-36, 41-43	3	3
22:30	1-8, 11-15, 18, 20-22, 26, 28, 29, 34-36, 41-43	2	1
23:00	1-8, 11-15, 18, 20-22, 26, 28-30, 34-36, 41-43	1	4
23:30	1-8, 11-15, 18, 20-22, 26-29, 34-36, 41, 43	5	3
24:00	1-8, 11-15, 18, 20-22, 26, 28-30, 34-36, 41, 43	4	4

### 4.3.3 Permodelan dengan Hibrida ARIMAX-DNN

Analisis selanjutnya yang akan dilakukan adalah permodelan dengan hibrida ARIMAX-DNN. Data yang digunakan untuk permodelan hibrida ARIMAX-DNN merupakan residual dari model ARIMAX yang telah di normalisasi dan input yang digunakan pada model DNN adalah lag signifikan dari komponen ARIMAX dank komponen ARIMAX antara lain  $T$ ,  $D_1^W$ ,  $D_2^W$ ,  $D_3^W$ ,  $D_4^W$ ,  $D_5^W$ ,  $D_6^W$ ,  $D_7^W$ ,  $D_1^V$ ,  $D_2^V$ ,  $D_3^V$ ,  $D_4^V$ ,  $D_5^V$ ,  $D_6^V$ ,  $D_7^V$ ,  $D_8^V$ ,  $D_9^V$ ,  $D_{10}^V$ ,  $D_{11}^V$ ,  $D_{12}^V$ ,  $D_{13}^V$ ,  $D_{14}^V$ ,  $D_{15}^V$ ,  $D_{16}^V$ ,  $D_{17}^V$ ,  $D_{18}^V$ ,  $D_{19}^V$ ,  $D_{20}^V$ , dan  $D_{21}^V$ . Pada penelitian ini akan digunakan dua *hidden layer* dengan masing-masing *hidden layer* merupakan kombinasi 1 sampai dengan 5 neuron dan digunakan fungsi aktivasi sigmoid untuk *hidden layer* dan fungsi aktivasi linear untuk *output layer*. Pada penelitian ini juga akan dilakukan 10 replikasi. Sehingga didapatkan arsitektur DNN optimum untuk data skenario 2 jam 20:00 adalah 3 neuron pada *hidden layer* 1 dan 2 neuron pada *hidden layer* 2 yang akan ditampilkan pada Gambar 4.27. Sedangkan persamaan model DNN akan ditampilkan sebagai berikut:

$\hat{Y}_{40,t} = \hat{L}_t + \hat{N}_t$  dengan  $\hat{N}_t$  merupakan hasil normalisasi dari  $\hat{N}_t^*$  dimana

$$\begin{aligned}
Y_{40,t} = & 0,43t + 3141,4D_{1,t}^W + 3147,1D_{2,t}^W + 3150,4D_{3,t}^W + 3144,2D_{4,t}^W + 3132,1D_{5,t}^W \\
& + 3034,8D_{6,t}^W + 2951,7D_{7,t}^W - 341,48D_{1,t}^V - 241,52D_{2,t}^V - 268,84D_{3,t}^V - 179,91D_{4,t}^V \\
& - 231,63D_{5,t}^V - 270,34D_{6,t}^V - 121,46D_{7,t}^V - 106,32D_{8,t}^V - 131,77D_{9,t}^V - 356,37D_{10,t}^V \\
& - 140,91D_{11,t}^V - 359,33D_{12,t}^V - 624,26D_{13,t}^V - 826,88D_{14,t}^V - 745,85D_{15,t}^V + 617,62D_{16,t}^V \\
& - 519,13D_{17,t}^V - 326,08D_{18,t}^V + 324,28D_{19,t}^V + 263,92D_{20,t}^V + 246,62D_{21,t}^V \\
& + \frac{1}{(1 - 0,30B - 0,15B^2 - 0,09B^3 - 0,05B^6 - 0,07B^7 - 0,08B^{18} - 0,07B^{46})} a_t \\
\hat{N}_t^* = & 0,0006 + 0,83fh_1^2(.) + 0,69fh_2^2(.)
\end{aligned}$$

dengan

$$fh_1^2(.) = (1 + \exp(-(-0,20 + 0,82fh_1^1(.) - 0,73fh_2^1(.) + 0,66fh_3^1(.))))^{-1}$$

$$fh_2^2(.) = (1 + \exp(-(-0,64 - 0,87fh_1^1(.) + 1,42fh_2^1(.) - 0,43fh_3^1(.))))^{-1}$$


dengan

$$fh_1^1(.) = (1 + \exp(-(-0,37 - 1,82Z_{t-1} + 0,48Z_{t-2} + \dots + 0,66D_{21}^V)))^{-1}$$

$$fh_2^1(.) = (1 + \exp(-(1,71 + 0,32Z_{t-1} - 0,58Z_{t-2} + \dots + 1,04D_{21}^V)))^{-1}$$


$$fh_3^1(.) = (1 + \exp(-(-1,22 - 9,12Z_{t-1} - 7,77Z_{t-2} + \dots + 4,40D_{21}^V)))^{-1}$$

Berdasarkan model persamaan yang telah ditentukan, dilakukan perbandingan data aktual dan ramalan, yang ditunjukkan pada Gambar 4.28 sebagai berikut:



**Gambar 4.27** Perbandingan Data Aktual jam 20:00 dengan Data Ramalan dengan menggunakan model Hibrida ARIMAX-DNN





**Gambar 4.28** Arsitektur DNN pada Model Hibrida ARIMAX-DNN untuk Data Beban Listrik pada jam 20:00

Berikut merupakan arsitektur model hibrida ARIMAX-DNN untuk masing-masing waktu:

**Tabel 4.19** Arsitektur untuk Permodelan Hibrida ARIMAX-DNN pada Data Beban Listrik

Jam	Input PACF	Jumlah Neurom	
		Hidden 1	Hidden 2
00:30	1,3,4,7,18	1	1
01:00	1,3,7	4	1
01:30	1,3,7	1	1
02:00	1,3,7	2	2
02:30	1,2,3	4	2
03:00	1,3,7	3	2
03:30	1,3	5	4
04:00	1,3	5	4
04:30	1,3	2	1

**Tabel 4.19** Arsitektur untuk Permodelan Hibrida ARIMAX-DNN pada Data Beban Listrik (lanjutan)

Jam	Input PACF	Jumlah Neurom	
		<i>Hidden 1</i>	<i>Hidden 2</i>
05:00	1,3,7	1	1
05:30	1,3,7	1	1
06:00	1,2,7	1	1
06:30	1,2,5,7	4	4
07:00	1,2,5,7	4	5
07:30	1,2,4,6,7	1	2
08:00	1,2,4,7,14	2	2
08:30	1,2,4,7	4	5
09:00	1,2,4,7	2	4
09:30	1,2,4,7,14,19,20	3	5
10:00	1,2,4,7,19,20	4	4
10:30	1,2,4,7,14,19,20	4	5
11:00	1,2,4,7,9,14	1	3
11:30	1,2,4,7,14	2	4
12:00	1,2,7,14	1	5
12:30	1,2,7,14	3	1
13:00	1,2,3,7,14	4	5
13:30	1,2,7,14	3	2
14:00	1,2,7,14	1	2
14:30	1,2,7,14	3	3
15:00	1,2,7,14	4	3
15:30	1,2,3,7,8	4	4
16:00	1,2,3,7,8	3	1
16:30	1,2,3,7	5	4
17:00	1,2,3,7,16	1	1
17:30	1,2,3,7,10	1	1
18:00	1,2,3,7,10,18	2	5
18:30	1,2,3,7,10,18,24	1	4
19:00	1,2,3,7,10,15,18	3	1
19:30	1,2,3,7,10,15	4	3
20:00	1,2,3,6,7,18,46	3	2
20:30	1,2,3,7,18	1	1
21:00	1,2,3,7,18	1	1
21:30	1,2,3,4,18	5	3
22:00	1,2,3,4,46	2	3

**Tabel 4.19** Arsitektur untuk Permodelan Hibrida ARIMAX-DNN pada Data Beban Listrik (lanjutan)

Jam	Input PACF	Jumlah Neurom	
		<i>Hidden 1</i>	<i>Hidden 2</i>
22:30	1,2,3,4,7	4	2
23:00	1,2,3,7	3	2
23:30	1,2,3,7	2	2
24:00	1,2,5,7	2	2

#### 4.4 Perbandingan Model ARIMAX, DNN, dan Hibrida ARIMAX-DNN

Untuk mengetahui kebaikan model ARIMAX, DNN, dan Hibrida ARIMAX -DNN pada setiap waktu, maka dilakukan evaluasi kebaikan model dengan hasil pada Tabel 4.20.

**Tabel 4.20** Perbandingan RMSEP untuk Masing-masing Model

Jam	ARIMAX		DNN		ARIMAX-DNN	
	Data Training	Data Testing	Data Training	Data Testing	Data Training	Data Testing
00:30	68,03	159,11	65,35	<b>115,83</b>	67,20	150,36
01:00	65,50	154,89	62,82	<b>112,60</b>	63,46	140,24
01:30	65,24	152,66	57,64	<b>106,94</b>	63,62	134,37
02:00	63,82	151,98	60,35	<b>115,18</b>	62,79	139,61
02:30	63,46	154,01	60,33	<b>120,54</b>	61,45	133,16
03:00	64,41	165,45	61,53	<b>131,14</b>	60,06	153,56
03:30	66,21	187,53	55,72	<b>145,69</b>	64,96	165,95
04:00	66,62	195,71	59,53	<b>153,56</b>	65,06	178,01
04:30	62,95	172,07	53,32	<b>140,91</b>	61,47	155,86
05:00	60,69	146,70	68,34	<b>96,29</b>	60,12	127,30
05:30	61,89	145,27	52,90	<b>97,11</b>	61,36	128,06
06:00	63,22	148,54	61,01	<b>118,24</b>	62,74	131,18
06:30	62,78	125,40	54,61	<b>99,30</b>	62,39	111,86
07:00	59,54	111,25	50,71	<b>89,44</b>	59,42	96,15
07:30	66,26	117,76	59,56	<b>87,32</b>	66,05	110,28
08:00	72,01	126,23	64,15	<b>90,05</b>	72,20	115,37
08:30	80,63	132,78	63,05	<b>98,09</b>	78,79	122,99
09:00	85,42	135,30	73,71	<b>102,61</b>	84,63	126,03
09:30	89,69	140,52	78,34	<b>101,45</b>	89,85	131,40
10:00	90,21	141,50	79,06	<b>103,58</b>	89,71	135,62

**Tabel 4.20** Perbandingan RMSEP untuk Masing-masing Model (lanjutan)

Jam	ARIMAX		DNN		ARIMAX-DNN	
	Data <i>Training</i>	Data <i>Testing</i>	Data <i>Training</i>	Data <i>Testing</i>	Data <i>Training</i>	Data <i>Testing</i>
10:30	91,94	145,91	80,02	<b>106,52</b>	91,23	136,87
11:00	99,12	151,06	98,12	<b>115,10</b>	98,86	145,22
11:30	97,57	154,23	93,83	<b>112,37</b>	98,88	148,42
12:00	90,06	145,72	88,14	<b>107,32</b>	89,94	140,93
12:30	87,55	145,79	68,39	<b>105,65</b>	87,31	123,06
13:00	95,22	151,20	81,32	<b>106,83</b>	94,67	145,28
13:30	102,33	157,98	91,84	<b>107,87</b>	100,83	148,73
14:00	99,79	154,28	88,46	<b>104,67</b>	99,66	148,26
14:30	95,60	148,89	89,84	<b>105,56</b>	94,99	142,73
15:00	91,07	147,65	84,33	<b>107,76</b>	87,27	137,18
15:30	89,25	150,84	80,57	<b>108,36</b>	87,96	142,00
16:00	89,46	148,84	78,54	<b>111,90</b>	82,34	141,99
16:30	91,29	142,35	66,44	<b>100,30</b>	90,01	134,87
17:00	94,74	140,38	86,15	<b>113,35</b>	89,40	134,93
17:30	102,74	160,94	84,25	<b>140,88</b>	102,55	157,31
18:00	101,64	151,18	92,09	<b>130,75</b>	101,04	127,01
18:30	98,67	151,01	65,59	<b>106,73</b>	98,45	129,17
19:00	95,53	152,58	91,40	<b>99,80</b>	95,18	112,21
19:30	95,62	152,10	89,27	<b>96,13</b>	95,62	123,66
20:00	92,11	145,99	68,05	<b>97,48</b>	93,06	107,83
20:30	91,38	157,35	84,88	<b>106,64</b>	91,58	121,41
21:00	89,08	157,73	88,59	<b>119,03</b>	89,26	124,83
21:30	82,41	154,66	77,41	<b>124,87</b>	82,07	126,93
22:00	77,23	151,87	70,14	<b>120,95</b>	77,76	148,05
22:30	71,02	156,71	68,56	<b>124,33</b>	70,84	140,29
23:00	65,90	151,29	66,31	<b>116,34</b>	65,13	148,52
23:30	60,88	145,22	53,90	<b>111,61</b>	60,38	128,96
24:00	60,10	139,10	55,51	<b>108,02</b>	59,19	137,67

**Tabel 4.21** Perbandingan sMAPE untuk Masing-masing Model

Jam	ARIMAX		DNN		ARIMAX-DNN	
	Data <i>Training</i>	Data <i>Testing</i>	Data <i>Training</i>	Data <i>Testing</i>	Data <i>Training</i>	Data <i>Testing</i>
00:30	1,98%	4,52%	1,84%	<b>3,43%</b>	1,95%	4,26%
01:00	1,92%	4,52%	1,81%	<b>3,39%</b>	1,83%	3,96%
01:30	1,92%	4,49%	1,63%	<b>3,14%</b>	1,85%	3,81%


**Tabel 4.21** Perbandingan sMAPE untuk Masing-masing Model (lanjutan)

Jam	ARIMAX		DNN		ARIMAX-DNN	
	Data Training	Data Testing	Data Training	Data Testing	Data Training	Data Testing
02:00	1,90%	4,51%	1,73%	<b>3,60%</b>	1,85%	4,04%
02:30	1,89%	4,60%	1,76%	<b>3,89%</b>	1,80%	3,72%
03:00	1,89%	5,05%	1,77%	<b>4,36%</b>	1,83%	4,54%
03:30	1,90%	5,74%	1,53%	<b>3,54%</b>	1,84%	4,44%
04:00	1,87%	5,96%	1,63%	<b>3,86%</b>	1,80%	4,99%
04:30	1,76%	5,01%	1,48%	<b>4,16%</b>	1,70%	4,39%
05:00	1,64%	3,73%	1,82%	<b>2,55%</b>	1,61%	3,19%
05:30	1,62%	3,28%	1,35%	<b>2,56%</b>	1,60%	3,07%
06:00	1,69%	3,64%	1,61%	<b>3,01%</b>	1,67%	3,49%
06:30	1,71%	3,11%	1,46%	<b>2,71%</b>	1,69%	2,81%
07:00	1,71%	2,76%	1,57%	<b>2,44%</b>	1,68%	2,42%
07:30	1,78%	2,85%	1,59%	<b>2,31%</b>	1,78%	2,61%
08:00	1,86%	2,97%	1,61%	<b>2,33%</b>	1,83%	2,70%
08:30	1,95%	3,03%	1,52%	<b>2,49%</b>	1,86%	2,84%
09:00	1,99%	3,06%	1,65%	<b>2,58%</b>	1,96%	2,96%
09:30	2,02%	3,16%	1,72%	<b>2,51%</b>	2,01%	3,01%
10:00	2,04%	3,20%	1,73%	<b>2,60%</b>	2,01%	3,10%
10:30	2,06%	3,29%	1,75%	<b>2,62%</b>	2,03%	3,10%
11:00	2,17%	3,41%	2,15%	<b>2,85%</b>	2,15%	3,32%
11:30	2,18%	3,47%	2,11%	<b>2,69%</b>	2,15%	3,39%
12:00	2,12%	3,41%	2,07%	<b>2,74%</b>	2,20%	3,80%
12:30	2,11%	3,47%	1,77%	3,35%	2,11%	<b>2,35%</b>
13:00	2,22%	3,48%	1,96%	<b>2,70%</b>	2,18%	3,37%
13:30	2,32%	3,56%	2,06%	<b>2,64%</b>	2,25%	3,42%
14:00	2,27%	3,48%	1,98%	<b>2,56%</b>	2,25%	3,37%
14:30	2,20%	3,39%	2,08%	<b>2,58%</b>	2,17%	3,28%
15:00	2,11%	3,42%	1,96%	<b>2,66%</b>	1,98%	3,26%
15:30	2,08%	3,55%	1,88%	<b>2,61%</b>	2,03%	3,37%
16:00	2,02%	3,53%	1,79%	<b>2,71%</b>	1,92%	3,39%
16:30	2,17%	3,38%	1,64%	<b>2,38%</b>	2,12%	3,19%
17:00	2,29%	3,35%	2,07%	<b>2,81%</b>	2,15%	3,20%
17:30	2,28%	3,72%	1,88%	<b>3,31%</b>	2,26%	3,62%
18:00	1,80%	2,99%	1,62%	<b>2,86%</b>	1,77%	2,61%
18:30	1,66%	3,07%	1,30%	<b>2,14%</b>	1,64%	2,62%
19:00	1,64%	3,15%	1,58%	<b>2,03%</b>	1,62%	2,22%


**Tabel 4.21** Perbandingan sMAPE untuk Masing-masing Model (lanjutan)

Jam	ARIMAX		DNN		ARIMAX-DNN	
	Data Training	Data Testing	Data Training	Data Testing	Data Training	Data Testing
19:30	1,64%	3,18%	1,54%	<b>2,04%</b>	1,63%	2,45%
20:00	1,67%	2,99%	1,40%	2,16%	1,65%	2,16%
20:30	1,75%	3,43%	1,62%	<b>2,33%</b>	1,75%	2,67%
21:00	1,84%	3,59%	1,84%	<b>2,77%</b>	1,83%	2,81%
21:30	1,83%	3,69%	1,77%	<b>2,88%</b>	1,81%	2,90%
22:00	1,87%	3,78%	1,77%	<b>3,01%</b>	1,87%	3,68%
22:30	1,82%	4,14%	1,76%	<b>3,27%</b>	1,80%	3,57%
23:00	1,77%	4,14%	1,78%	<b>3,14%</b>	1,73%	4,07%
23:30	1,71%	4,06%	1,46%	<b>3,01%</b>	1,68%	3,84%
24:00	1,74%	4,01%	1,56%	<b>3,04%</b>	1,70%	3,93%


Pada Tabel 4.20 dan Tabel 4.21 menunjukkan bahwa berdasarkan nilai RMSE dan sMAPE model DNN merupakan model terbaik yang dapat digunakan untuk peramalan 365 hari kedepan pada data beban listrik per setengah jam wilayah Jateng dan DIY. Selanjutnya dilakukan perhitungan akurasi secara horizon yang terdiri dari *short horizon* (1-7 hari), *medium horizon* (1-181 hari), dan *long horizon* (1-365 hari). Perhitungan *multiple horizon* untuk beban listrik ditampilkan pada Lampiran 12. Berdasarkan perhitungan RMSEP untuk *multiple horizon* pada Tabel 4.23 didapatkan model terbaik untuk masing-masing horizon pada Gambar 4.29.

**Gambar 4.29** Hasil Model Terbaik untuk Masing-masing Horizon

Berdasarkan Gambar 4.28, diketahui bahwa DNN baik untuk *horizon short, medium* dan *long*. Hal ini menunjukkan bahwa semakin panjang data maka metode *Machine Learning* seperti DNN dapat melatih bobotnya lebih optimal (Makridrakis dkk, 2018). Peramalan beban listrik wilayah Jateng dan DIY pada tahun 2018 dilakukan dengan metode terbaik yang telah didapatkan sebelumnya. Hasil peramalan 7 hari kedepan beban listrik wilayah Jateng dan DIY pada tahun 2018 ditampilkan pada Gambar 4.30.



**Gambar 4.30** Plot Hasil Peramalan Beban Listrik Per Setengah Jam Periode 2018



**Gambar 4.30** Plot Hasil Peramalan Beban Listrik Per Setengah Jam Periode 2018 (lanjutan)

Selanjutnya melihat hubungan antara pola data hasil Uji White (uji linearitas) dengan model terbaik.



**Tabel 4.22** Hubungan Pola Data dengan Model Terbaik

<b>Pola Data</b>	<b>Model Terbaik</b>			<b>Total</b>
	<b>ARIMAX</b>	<b>DNN</b>	<b>Hibrida</b>	
Linear	9	16	15	40
Nonlinear	4	3	1	8
Total	13	19	16	48

Pada Tabel 4.22 menunjukkan bahwa dari 48 *series* yang digunakan pada penelitian ini diketahui bahwa 83,33% memiliki pola data linear dan 16,67 % memiliki pola data nonlinear. Selain itu, dari 40 *series* data yang memiliki pola linear diketahui bahwa 40% menggunakan model DNN, 37,5% menggunakan model Hibrida ARIMAX-DNN, dan 22,5% menggunakan model ARIMAX. Sedangkan dari 8 *series* data yang memiliki pola nonlinear diketahui bahwa 50% menggunakan model ARIMAX, 37,5% menggunakan model DNN, dan 12,5% menggunakan model Hibrida ARIMAX-DNN. Namun, dalam pengujian ini terdapat kelemahan yaitu asumsi distribusi normal dari seluruh model tidak dapat terpenuhi pada analisis penelitian ini sehingga diduga hasil dari Uji White (uji linearitas) juga tidak valid. Selain pola data, didapatkannya suatu model terbaik untuk peramalan juga dipengaruhi oleh faktor lain misalnya adanya *noise/outlier* yang terdapat di dalam data. Hasil RMSEP dari model terbaik yang telah didapatkan selanjutnya dibandingkan dengan standar deviasi data. Hal ini dilakukan untuk mengetahui hubungan antara karakteristik beban listrik dengan ketepatan ramalan. Perbandingan standar deviasi data yang telah diurutkan dari yang terkecil hingga yang terbesar dengan hasil RMSEP model terbaik akan ditampilkan pada Tabel 4.23.

**Tabel 4.23** Hubungan Karakteristik Data dengan RMSEP

<b>Jam</b>	<b>Standar Deviasi</b>	<b>RMSEP</b>
21:30	224,4	64,41
23:30	205,2	65,12
22:00	217,0	73,81
19:00	252,2	75,90
00:00	201,1	76,04
23:00	208,5	77,61


**Tabel 4.23** Hubungan Karakteristik Data dengan RMSEP (lanjutan)

<b>Jam</b>	<b>Standar Deviasi</b>	<b>RMSEP</b>
22:30	213,6	77,99
20:30	239,6	79,56
19:30	249,6	79,90
20:00	244,1	81,17
21:00	232,7	81,58
07:30	239,2	87,99
03:30	210,6	89,02
02:00	192,8	89,64
18:30	258,6	90,28
03:00	197,1	91,48
02:30	193,2	92,31
01:00	195,7	98,11
01:30	194,2	98,11
00:30	197,6	100,97
04:00	221,0	106,45
04:30	216,5	107,49
06:30	212,8	107,77
08:00	263,5	107,89
07:00	213,1	108,87
18:00	288,2	120,22
12:30	298,3	124,73
06:00	216,8	125,82
05:00	209,0	133,76
13:30	343,1	139,95
05:30	211,8	140,21
12:00	301,6	140,24
15:00	324,7	141,7
09:00	300,6	142,59
08:30	289,4	142,83
15:30	321,2	144,71
14:00	338,6	146,04
10:00	311,6	147,69
14:30	332,8	149,05
16:00	305,2	149,79
13:00	318,4	150,87
09:30	306,9	154,84
10:30	319,1	158,86

**Tabel 4.23** Hubungan Karakteristik Data dengan RMSEP (lanjutan)

Jam	Standar Deviasi	RMSEP
16:30	292,0	162,3
11:30	323,9	164,36
17:30	295,1	178,17
17:00	284,6	179,05
11:00	326,9	181,53

Berdasarkan Tabel 4.23 dapat diketahui bahwa pada data beban pemakaian listrik jam 18:30 hingga 03:30 memiliki nilai RMSEP dibawah 100. Sedangkan diluar 18:30 hingga 03:30 memiliki nilai RMSEP diatas 100. Selain itu, dari Tabel 4.23 dapat dilihat nilai RMSEP lebih kecil dibandingkan dengan nial standar deviasi. Hal ini menunjukkan bahwa permodelan yang telah dilakukan sudah sesuai. Berikut ini merupakan grafik hubungan antara standar deviasi data dengan RMSEP:

**Gambar 4.31** Scatterplot Standar Deviasi dan RMSEP

Gambar 4.31 menunjukkan bahwa antara standar deviasi data dengan RMSEP memiliki hubungan yang searah. Semakin besar standar deviasi data maka semakin besar RMSEP. Selanjutnya, dilakukan pengujian korelasi dengan korelasi Pearson dan didapatkan Nilai Korelasi Pearson sebesar 0,763 dan nilai *p-value* sebesar 0,000. Nilai *p-value* sebesar 0,000 menunjukkan bahwa standar deviasi dan RMSEP berkorelasi sedangkan nilai Korelasi Pearson 0,763 menunjukkan bahwa antara standar deviasi dan RMSEP memiliki korelasi yang cukup tinggi dan searah.

*(halaman sengaja dikosongkan)*

## BAB V

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Berdasarkan analisis yang telah dilakukan, diperoleh kesimpulan sebagai berikut.

1. Pada data simulasi mengandung komponen tren, musiman harian, variasi kalender dan *noise*. Untuk data simulasi yang mengandung *noise* linear, model Hibrida ARIMAX-DNN merupakan model terbaik yang dapat digunakan untuk peramalan. Sedangkan pada data simulasi yang mengandung *noise* nonlinear, secara umum model Hibrida ARIMAX-DNN merupakan model terbaik kecuali pada *series* jam 20:00 yang model terbaiknya adalah model DNN. Berdasarkan perhitungan akurasi untuk beberapa periode *horizon* diketahui bahwa pada data yang mengandung *noise* linear model ARIMAX merupakan model terbaik pada *horizon short* dan model Hibrida ARIMAX-DNN merupakan model terbaik pada *horizon medium* dan *long*. Sedangkan pada data yang mengandung *noise* nonlinear model Hibrida ARIMAX-DNN merupakan model terbaik pada *horizon short, medium, dan long*.
2. Beban listrik per setengah jam pada wilayah Jawa Tengah dan DIY memiliki pola tren naik serta data memiliki *outlier*. Hal ini dapat terlihat dari adanya data beban yang jauh lebih rendah jika dibandingkan dengan beban listrik lainnya. Pola karakteristik dari data beban listrik cukup fluktuatif dan dipengaruhi oleh keragaman jenis pemakaian listrik oleh konsumen. Pada jam 19:00 merupakan waktu terjadinya beban puncak. Selain itu terdapat perbedaan pemakaian listrik pada hari Sabtu dan Minggu lebih rendah dibandingkan dengan hari kerja yaitu Senin hingga Jumat.
3. Pada data beban listrik per setengah jam mengandung komponen tren, musiman harian, variasi kalender dan *outlier*. Hasil permodelan dengan metode ARIMAX untuk data beban listrik per setengah jam menunjukkan bahwa secara umum

residual pada model ARIMA tidak dapat memenuhi asumsi distribusi normal. Hal ini disebabkan karena analisis ini tidak dilakukan pemodelan dengan deteksi outlier. Sedangkan pada data jam 17:30 dan 18:30 residual model ARIMA tidak dapat memenuhi asumsi distribusi normal dan *white noise*. Hasil pemodelan dengan metode DNN dan hibrida ARIMAX-DNN untuk data beban listrik per setengah jam menunjukkan bahwa tidak ada karakteristik khusus dalam penentuan jumlah neuron untuk masing-masing *hidden layer*. Jumlah neuron untuk masing-masing hidden layer ditentukan dari hasil kombinasi terbaik dari percobaan yang telah dilakukan.

4. Model DNN lebih baik dibandingkan model ARIMAX dan Hibrida ARIMAX-DNN untuk meramalkan beban listrik per setengah jam pada wilayah Jawa Tengah dan DIY. Berdasarkan perhitungan *horizon* untuk berbagai periode, DNN baik untuk *horizon short, medium* dan *long*. Hal ini disebabkan karena semakin panjang data maka metode Machine Learning seperti DNN dapat melatih bobotnya lebih optimal (Makridakis dkk, 2018).

## 5.2 Saran

Berdasarkan analisis yang telah dilakukan, dapat dirumuskan saran sebagai pertimbangan penelitian selanjutnya diantaranya perlu memperhatikan komponen-komponen yang membentuk data pada kajian simulasi, sehingga hasil yang didapatkan lebih representatif. Selanjutnya, penggunaan deteksi outlier agar asumsi residual yang berdistribusi normal dapat terpenuhi. Selain itu, untuk mengoptimalkan DNN sebelum dilakukan analisis sebaiknya dilakukan *preprocessing* dengan cara mentransformasi data, *deseasonalizing* data, *detrending* data, atau kombinasi dari ketiga cara tersebut dan kemudian dilakukan *scaling* data seperti penelitian yang dilakukan oleh Makridakis dkk. (2018).

## DAFTAR PUSTAKA

- Bowerman, B., & O'Connel, R. (1993). *Forecasting and Time Series : An Applied Approach*. California: Dixbury Press.
- Chong, E. K., & Zak, S. H. (2001). *An Introduction to Optimization* (2nd ed.). Canada: John Wiley & Sons, Inc.
- Cryer, J. D., & Chan, K.-S. (2008). *Time Series Analysis With Applications in R*. USA: Springer Science dan Business Media, LLC.
- Daniel, W. (2000). *Statistik Nonparametrik Terapan*. (A. T. W, Penerj.) Jakarta: PT Gramedia Pusaka Utama.
- Din, G. M., & Marnerides, A. K. (2017). Short Term Power Load Forecasting Using Deep Neural Network. *International Conference on Computing, Networking and Communications (ICNC): Green Computing, Networking, and Communication*. Santa Clara, CA, USA : IEEE.
- Dwisatya, R., & Kirom, M. (2016). Prediksi Beban Listrik Jangka Pendek Menggunakan Algoritma Feed Forward Back Propagation dengan Mempertimbangkan Variasi Tipe Hari. *Jurnal Teknik Elektro, Komputer dan Informatika*, 14(1), 34-40.
- Eljazzar, M. M., & Hemayed, E. E. (2017). Enhancing Electric Load Forecasting of ARIMA and ANN Using Adaptive Fourier Series. *IEEE PowerTech*.
- ESDM, K. (2016). *Rencana Umum Penyediaan Tenaga Listrik PT. PLN (Persero) Tahun 2016-2024*. Jakarta.
- Fausett, L. (1994). *Fundamentals of Neural Networks : Architectures, Algorithms, and Applications*. New Jersey: Prentice Hall, Inc.
- Franse, A. (2017). *Using The Multiplicative Double Seasonal Holt-Winters Methods To Forecast Short Term Electricity*

- Demand*. Rotterdam: Department of Econometrics, Erasmus School of Economics, Erasmus University.
- Gooijer, J. G., & Hyndman, R. J. (2006). 25 Years of Time Series Forecasting. *International Journal of Forecasting*, 22, 443-473.
- He, W. (2017). Load Forecasting via Deep Neural Networks. *5th International Conference on Information Technology and Quantitative Management, ITQM* (hal. 308-314). Elsevier B.V.
- Hossen, T., Plathottam, S. J., Angamuthu, R. K., Ranganathan, P., & Salehfar, H. (2017). Short-Term Load Forecasting Using Deep Neural Network (DNN). *Power Symposium (NAPS), 2017 North American*. Morgantown, WV, USA: IEEE.
- Hyndman, R. J., & Koehler, A. B. (2006). Another Look at Measures of Forecast Accuracy. *International Journal of Forecasting*, 22, 679-688.
- Karthika, Margaret, V., & Balaraman, K. (2017). Hybrid Short Term Load Forecasting Using ARIMA-SVM. *International Conference on Innovations in Power and Advanced Computing Technologies* (hal. 1-7). Vellore, India: IEEE.
- Khusna, H., & Suhartono. (2015). Pendekatan Percentile Error Bootstrap pada Model Double Seasonal Holt-Winters, Double Seasonal ARIMA, dan Naïve untuk Peramalan Beban Listrik Jangka Pendek Area Jawa Timur-Bali. *Jurnal Sains dan Seni ITS*, 4(1), 43-48.
- Koran SINDO. (2017, Oktober 25). *Catat! Tarik Investor, Ketersediaan Listrik di Kawasan Industri Perlu Diprioritaskan*. Dipetik Maret 22, 2018, dari Okezone: <https://economy.okezone.com/read/2017/10/25/320/1801935/catat-tarik-investor-ketersediaan-listrik-di-kawasan-industri-perlu-diprioritaskan>



- Lewis, N. (2016). *Deep Learning Made Easy With R : A Gentle Introduction for Data Science*. AusCov.
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: Results, Conclusions and Implications. *International Journal of Forecasting*, 451–476.
- Makridakis, S., & Hibon, M. (2002). The M3-Competition: Results, Conclusions and Implications. *International Journal of Forecasting*, 451–476.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning Forecasting Methods : Concerns and Ways Forward. *Plos One*.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting : Methods and Applications (3rd Edition ed.)*. USA: Wiley.
- Muslim, S., Joko, & Wanarti, P. (2008). *Teknik Pembangkit Tenaga Listrik Jilid 1 Untuk SMK*. Jakarta: Direktorat Pembinaan Sekolah Menengah Kejuruan .
- Nagaselvi, M., & Deepa, T. (2015). Weather Forecasting using Deep Feed Forward Neural Network (DFFNN) and Fuzzy Outlier Removal. *Journal on Science Engineering & Technology*(2), 215-225.
- Ozerdem, O. C., Olaniyi, E. O., & Oyedotun, O. K. (2017). Short Term Load Forecasting Using Particle Swarm Optimization Neural Network. *International Conference on Theory and Application of Soft Computing, Computing with Words and Perception, ICSCCW* (hal. 382-393). Budapest, Hungary: Elsevier B.V.
- Pradipika, C. L., Handoko, S., & Winardi, B. (2017). Peramalan Beban Puncak Harian Pada Sistem PT.PLN APB Jawa Tengah dan DIY Menggunakan Metode Jaringan Syaraf Tiruan– Algoritma Genetika. *Transmisi*, 19(1), 28-33.
- Pujangga, R. F. (2017, Oktober 25). *Sasar Industri Besar, PLN Siapkan Pasokan Listrik Industri 270 MVA*. Dipetik Maret

- 22, 2018, dari Tribun News: <http://jateng.tribunnews.com/2017/10/25/sasar-industri-besar-pln-siapkan-pasokan-listrik-industri-270-mva>
- Purnamasari, I., & Suhartono. (2012). *TLSAR Berbasis Regresi Time Series, ARIMAX, dan Neural Network untuk Peramalan Beban Listrik*. Surabaya: Tesis Statistika ITS.
- Puspitasari, I., Akbar, M. S., & Suhartono. (2012). Model Dua Level Seasonal Autoregressive Hibrida ARIMA ANFIS untuk Peramaan Beban Listrik Jangka Pendek di Jawa Balli. *Jurnal Sains dan Seni ITS*.
- Rini, A. S. (2017, Oktober 24). *Relokasi Industri ke Jateng Berjalan, Jabodetabek Mengarah ke Teknologi*. Dipetik Maret 22, 2018, dari Semarang Bisnis: <http://semarang.bisnis.com/read/20171024/12/96789/relokasi-industri-ke-jateng-berjalan-jabodetabek-mengarah-ke-teknologi->
- Sari, D. A., Wahyudi, & Facta, M. (2007). *Peramalan Kebutuhan Beban Jangka Pendek Menggunakan Jaringan Syaraf Tiruan Backpropagation*. Semarang: Program S1 Jurusan Teknik Elektro Fakultas Teknik Universitas Diponegoro.
- Suhartono. (2007). *Feedforward Neural Network untuk Pemodelan Runtun Waktu*. Yogyakarta: Disertasi Doktoral, Universitas Gajah Mada.
- Suhartono, & Endharta, A. (2009). Peramalan Konsumsi Listrik Jangka Pendek dengan ARIMA Musiman Ganda dan Elman-Recurrent Neural Network. *Jurnal Teknik ITS*, 7(4), 183-190.
- Suswanto, D. (2009). *Sistem Distribusi Tenaga Listrik untuk Mahasiswa Teknik Elektro*. Padang: Jurusan Teknik Elektro Universitas Negeri Padang.
- Wei, W. W. (2006). *Time Series Analysis Univariate and Multivariate Methods* (2nd ed.). United States of America: Pearson Education, Inc.

Zhang, G. P. (2003). Time Series Forecasting Using A Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 159-175.

*(halaman sengaja dikosongkan)*

## LAMPIRAN

### Lampiran 1 Hasil ARIMAX pada Skenario 1

- Jam 04:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.72185	0.01832	39.4	<.0001	1	y	0
NUM1	0.2966	0.006602	44.92	<.0001	0	t	0
NUM2	2403.6	5.84153	411.46	<.0001	0	D1	0
NUM3	2525.1	5.83216	432.96	<.0001	0	D2	0
NUM4	2542	5.84099	435.21	<.0001	0	D3	0
NUM5	2539.5	5.85429	433.79	<.0001	0	D4	0
NUM6	2548	5.85909	434.88	<.0001	0	D5	0
NUM7	2508.4	5.85111	428.7	<.0001	0	D6	0
NUM8	2444.7	5.84636	418.15	<.0001	0	D7	0
NUM9	-479.359	12.15564	-39.44	<.0001	0	DV1	0
NUM10	-289.547	10.95854	-26.42	<.0001	0	DV2	0
NUM11	-256.814	14.02569	-18.31	<.0001	0	DV3	0
NUM12	-295.256	12.1403	-24.32	<.0001	0	DV4	0
NUM13	-183.566	12.24395	-14.99	<.0001	0	DV5	0
NUM14	-187.491	17.16859	-10.92	<.0001	0	DV6	0
NUM15	-97.017	12.26488	-7.91	<.0001	0	DV7	0
NUM16	-197.949	14.05756	-14.08	<.0001	0	DV8	0
NUM17	-183.174	12.22584	-14.98	<.0001	0	DV9	0
NUM18	-167.571	14.03414	-11.94	<.0001	0	DV10	0
NUM19	-67.2762	14.96923	-4.49	<.0001	0	DV11	0
NUM20	96.78006	18.42997	5.25	<.0001	0	DV12	0
NUM21	-122.184	19.92194	-6.13	<.0001	0	DV13	0
NUM22	-451.347	20.50354	-22.01	<.0001	0	DV14	0
NUM23	-664.519	20.50208	-32.41	<.0001	0	DV15	0
NUM24	-757.06	19.91824	-38.01	<.0001	0	DV16	0
NUM25	-696.842	18.42538	-37.82	<.0001	0	DV17	0
NUM26	-720.646	14.96614	-48.15	<.0001	0	DV18	0
NUM27	-124.519	14.02355	-8.88	<.0001	0	DV19	0
NUM28	-55.022	14.02409	-3.92	<.0001	0	DV20	0
NUM29	-238.458	14.11785	-16.89	<.0001	0	DV21	0

Autocorrelaion Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.11	5	0.1048	-0.037	0.02	0.054	0.008	0.001	-0.039
12	11.37	11	0.4127	0	-0.004	-0.012	0.027	-0.025	-0.003
18	19.2	17	0.3174	0.007	-0.05	-0.031	-0.031	0.018	0.022
24	24.49	23	0.377	0.027	0.028	0.02	0.03	-0.018	-0.021
30	27.4	29	0.5503	-0.024	-0.031	0.001	-0.02	0	0.003

36	37.79	35	0.3429	0.006	0.014	-0.027	-0.061	0.047	-0.005
42	42.93	41	0.3885	-0.03	-0.002	0.019	0.033	-0.004	0.032
48	45.77	47	0.5233	-0.013	-0.013	0.03	-0.023	-0.009	0

Test	Tests for Normality			
	---Statistic---		-----p Value-----	
Shapiro-Wilk	W	0.999294	Pr < W	0.8781
Kolmogorov-Smirnov	D	0.011214	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.016966	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.132935	Pr > A-Sq	>0.2500

## • Jam 08:00

### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.67327	0.01959	34.37	<.0001	1	y	0
NUM1	0.29872	0.00571	52.32	<.0001	0	t	0
NUM2	2663.3	5.14893	517.25	<.0001	0	D1	0
NUM3	2715.5	5.14088	528.21	<.0001	0	D2	0
NUM4	2716.4	5.14779	527.69	<.0001	0	D3	0
NUM5	2708.8	5.16136	524.83	<.0001	0	D4	0
NUM6	2685.5	5.16555	519.89	<.0001	0	D5	0
NUM7	2584	5.15666	501.1	<.0001	0	D6	0
NUM8	2371.1	5.15226	460.21	<.0001	0	D7	0
NUM9	-663.961	12.60127	-52.69	<.0001	0	DV1	0
NUM10	-371.494	11.3593	-32.7	<.0001	0	DV2	0
NUM11	-341.132	14.54134	-23.46	<.0001	0	DV3	0
NUM12	-458.762	12.58937	-36.44	<.0001	0	DV4	0
NUM13	-334.811	12.6958	-26.37	<.0001	0	DV5	0
NUM14	-520.027	17.80395	-29.21	<.0001	0	DV6	0
NUM15	-235.027	12.71666	-18.48	<.0001	0	DV7	0
NUM16	-287.883	14.57661	-19.75	<.0001	0	DV8	0
NUM17	-255.691	12.68077	-20.16	<.0001	0	DV9	0
NUM18	-583.563	14.55257	-40.1	<.0001	0	DV10	0
NUM19	-672.281	15.18329	-44.28	<.0001	0	DV11	0
NUM20	-699.669	18.29822	-38.24	<.0001	0	DV12	0
NUM21	-1085.4	19.51386	-55.62	<.0001	0	DV13	0
NUM22	-1180.8	19.95403	-59.18	<.0001	0	DV14	0
NUM23	-765.537	19.95326	-38.37	<.0001	0	DV15	0
NUM24	-844.74	19.51191	-43.29	<.0001	0	DV16	0
NUM25	-777.586	18.29569	-42.5	<.0001	0	DV17	0
NUM26	-732.646	15.18146	-48.26	<.0001	0	DV18	0
NUM27	-800.604	14.54185	-55.06	<.0001	0	DV19	0
NUM28	-416.088	14.54195	-28.61	<.0001	0	DV20	0
NUM29	-409.397	14.64153	-27.96	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	3.14	5	0.6788	0.011	-0.031	0.014	0.026	-0.01	-0.008
12	15.73	11	0.1514	0.022	-0.059	-0.021	-0.006	0.044	0.046
18	20.76	17	0.2373	0.012	-0.027	0.022	0.039	0.001	0.023
24	34.09	23	0.0639	0.048	0.003	0.028	0.054	0.035	-0.041
30	38.36	29	0.1146	-0.019	-0.039	0.017	0.002	-0.019	-0.018
36	42.15	35	0.1892	-0.007	0.034	0.03	-0.001	-0.006	-0.018
42	46.09	41	0.2699	-0.012	-0.003	-0.028	-0.033	-0.018	0.017
48	56.92	47	0.1523	-0.006	0.002	-0.044	0.048	0.049	0.022

Tests for Normality				
Test	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.999007	Pr < W	0.6210
Kolmogorov-Smirnov	D	0.018278	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.058013	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.360984	Pr > A-Sq	>0.2500

- Jam 12:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.71323	0.01857	38.41	<.0001	1	y	0
NUM1	0.30443	0.006486	46.93	<.0001	0	t	0
NUM2	2853.6	5.75775	495.61	<.0001	0	D1	0
NUM3	2887.1	5.74857	502.24	<.0001	0	D2	0
NUM4	2866.2	5.75712	497.86	<.0001	0	D3	0
NUM5	2854	5.77057	494.57	<.0001	0	D4	0
NUM6	2764.3	5.77527	478.65	<.0001	0	D5	0
NUM7	2774.6	5.76703	481.12	<.0001	0	D6	0
NUM8	2457.3	5.76233	426.44	<.0001	0	D7	0
NUM9	-737.728	12.35818	-59.7	<.0001	0	DV1	0
NUM10	-387.245	11.14161	-34.76	<.0001	0	DV2	0
NUM11	-371.11	14.25852	-26.03	<.0001	0	DV3	0
NUM12	-473.57	12.34483	-38.36	<.0001	0	DV4	0
NUM13	-331.577	12.4485	-26.64	<.0001	0	DV5	0
NUM14	-414.914	17.45806	-23.77	<.0001	0	DV6	0
NUM15	-182.796	12.46853	-14.66	<.0001	0	DV7	0
NUM16	-217.521	14.2934	-15.22	<.0001	0	DV8	0
NUM17	-181.423	12.42978	-14.6	<.0001	0	DV9	0
NUM18	-478.507	14.26929	-33.53	<.0001	0	DV10	0
NUM19	-600.661	15.15812	-39.63	<.0001	0	DV11	0
NUM20	-669.528	18.59138	-36.01	<.0001	0	DV12	0
NUM21	-1003.6	20.04788	-50.06	<.0001	0	DV13	0
NUM22	-1197	20.60962	-58.08	<.0001	0	DV14	0

NUM23	-880.067	20.60918	-42.7	<.0001	0	DV15	0
NUM24	-931.088	20.04692	-46.45	<.0001	0	DV16	0
NUM25	-798.344	18.5902	-42.94	<.0001	0	DV17	0
NUM26	-712.893	15.15733	-47.03	<.0001	0	DV18	0
NUM27	-511	14.25866	-35.84	<.0001	0	DV19	0
NUM28	-299.681	14.26154	-21.01	<.0001	0	DV20	0
NUM29	-384.255	14.35378	-26.77	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.05	5	0.6925	-0.002	-0.018	0.031	0.018	0.003	-0.022
12	11.85	11	0.3753	-0.023	-0.02	0.009	-0.037	-0.02	0.057
18	12.62	17	0.7615	0.013	0.004	0.017	-0.003	0	0.008
24	16.42	23	0.8368	0.011	0.04	0.019	-0.014	0.014	0.008
30	28.51	29	0.4906	-0.038	-0.012	0.032	-0.032	-0.017	-0.065
36	42.98	35	0.1666	-0.024	-0.003	0.055	-0.067	0.021	0.033
42	47.65	41	0.2205	-0.034	0.01	-0.006	-0.011	0.006	-0.041
48	49.14	47	0.3875	0.02	-0.013	0.012	-0.009	0.013	-0.001

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.999252 Pr < W 0.8460
Kolmogorov-Smirnov	D	0.008377 Pr > D >0.1500
Cramer-von Mises	W-Sq	0.012309 Pr > W-Sq >0.2500
Anderson-Darling	A-Sq	0.131053 Pr > A-Sq >0.2500

- Jam 16:00

The ARIMA Procedure  
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.66209	0.01989	33.29	<.0001	1	y	0
NUM1	0.29822	0.005351	55.73	<.0001	0	t	0
NUM2	2973.3	4.8478	613.33	<.0001	0	D1	0
NUM3	3002.4	4.84026	620.3	<.0001	0	D2	0
NUM4	2966	4.84659	611.98	<.0001	0	D3	0
NUM5	2963.2	4.85979	609.74	<.0001	0	D4	0
NUM6	2937.3	4.86371	603.91	<.0001	0	D5	0
NUM7	2780.5	4.85491	572.73	<.0001	0	D6	0
NUM8	2559.7	4.85073	527.69	<.0001	0	D7	0
NUM9	-821.115	12.2617	-66.97	<.0001	0	DV1	0
NUM10	-455.475	11.05526	-41.2	<.0001	0	DV2	0
NUM11	-429.01	14.15361	-30.31	<.0001	0	DV3	0
NUM12	-491.646	12.25364	-40.12	<.0001	0	DV4	0
NUM13	-338.14	12.357	-27.36	<.0001	0	DV5	0
NUM14	-528.694	17.3282	-30.51	<.0001	0	DV6	0



NUM15	-234.667	12.37768	-18.96	<.0001	0	DV7	0
NUM16	-315.248	14.19318	-22.21	<.0001	0	DV8	0
NUM17	-268.858	12.33617	-21.79	<.0001	0	DV9	0
NUM18	-541.066	14.16413	-38.2	<.0001	0	DV10	0
NUM19	-384.415	14.71028	-26.13	<.0001	0	DV11	0
NUM20	-462.264	17.64304	-26.2	<.0001	0	DV12	0
NUM21	-849.118	18.75756	-45.27	<.0001	0	DV13	0
NUM22	-1193.7	19.15172	-62.33	<.0001	0	DV14	0
NUM23	-979.587	19.14914	-51.16	<.0001	0	DV15	0
NUM24	-989.709	18.75046	-52.78	<.0001	0	DV16	0
NUM25	-880.059	17.63365	-49.91	<.0001	0	DV17	0
NUM26	-820.091	14.70335	-55.78	<.0001	0	DV18	0
NUM27	-503.059	14.15587	-35.54	<.0001	0	DV19	0
NUM28	-419.409	14.15448	-29.63	<.0001	0	DV20	0
NUM29	-497.051	14.24669	-34.89	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	3.24	5	0.663	-0.017	0.033	-0.006	-0.007	-0.011	0.025
12	6.42	11	0.8436	-0.027	0.024	0.004	-0.026	-0.012	0.004
18	10.67	17	0.8731	0.03	-0.007	0.02	0.019	0.033	0.006
24	19.58	23	0.6674	0.013	0.032	0.048	0.023	0.045	-0.003
30	23.68	29	0.7444	-0.032	-0.02	-0.029	-0.001	-0.013	-0.018
36	29.99	35	0.7084	-0.005	0.008	0.043	0.011	0.018	0.043
42	35.84	41	0.6988	0.038	-0.031	0.031	0.012	0.011	0.016
48	39.01	47	0.7898	0.018	0.001	-0.026	0.006	-0.012	0.03

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.998913 Pr < W
Kolmogorov-Smirnov	D	0.015975 Pr > D
Cramer-von Mises	W-Sq	0.071841 Pr > W-Sq
Anderson-Darling	A-Sq	0.462813 Pr > A-Sq

- Jam 20:00

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.72349	0.01831	39.51	<.0001	1	y	0
NUM1	0.30042	0.006687	44.93	<.0001	0	t	0
NUM2	3533.6	5.91343	597.56	<.0001	0	D1	0
NUM3	3558.8	5.90397	602.78	<.0001	0	D2	0
NUM4	3559.7	5.91288	602.02	<.0001	0	D3	0
NUM5	3547.8	5.92628	598.65	<.0001	0	D4	0

NUM6	3507.5	5.9311	591.38	<.0001	0	D5	0
NUM7	3435.4	5.92304	580	<.0001	0	D6	0
NUM8	3343.1	5.91828	564.88	<.0001	0	D7	0
NUM9	-518.095	12.23813	-42.33	<.0001	0	DV1	0
NUM10	-269.055	11.03242	-24.39	<.0001	0	DV2	0
NUM11	-289.192	14.11727	-20.48	<.0001	0	DV3	0
NUM12	-248.918	12.22191	-20.37	<.0001	0	DV4	0
NUM13	-204.283	12.32537	-16.57	<.0001	0	DV5	0
NUM14	-242.764	17.28573	-14.04	<.0001	0	DV6	0
NUM15	-69.4415	12.34576	-5.62	<.0001	0	DV7	0
NUM16	-92.0923	14.15232	-6.51	<.0001	0	DV8	0
NUM17	-85.7778	12.31185	-6.97	<.0001	0	DV9	0
NUM18	-202.984	14.12872	-14.37	<.0001	0	DV10	0
NUM19	-379.761	15.08081	-25.18	<.0001	0	DV11	0
NUM20	-360.776	18.57996	-19.42	<.0001	0	DV12	0
NUM21	-658.946	20.09254	-32.8	<.0001	0	DV13	0
NUM22	-839.938	20.68303	-40.61	<.0001	0	DV14	0
NUM23	-673.701	20.68107	-32.58	<.0001	0	DV15	0
NUM24	-679.992	20.0875	-33.85	<.0001	0	DV16	0
NUM25	-528.575	18.57377	-28.46	<.0001	0	DV17	0
NUM26	-452.22	15.07666	-29.99	<.0001	0	DV18	0
NUM27	-140.841	14.12442	-9.97	<.0001	0	DV19	0
NUM28	-117.508	14.11717	-8.32	<.0001	0	DV20	0
NUM29	-179.534	14.21484	-12.63	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	0.79	5	0.9774	0.018	-0.005	-0.005	-0.007	-0.005	-0.01
12	5.34	11	0.9135	-0.017	-0.014	0.003	-0.006	-0.013	-0.049
18	16.84	17	0.4654	0.012	0.023	-0.006	-0.01	-0.082	-0.014
24	20.12	23	0.6347	0.019	-0.029	-0.01	-0.03	0	-0.004
30	24.73	29	0.6923	0.015	0.024	0.032	-0.019	-0.029	0
36	33.73	35	0.5292	-0.045	0.034	0.036	-0.008	-0.014	-0.036
42	37.95	41	0.6068	0.017	-0.033	-0.014	0.005	0.032	0.013
48	52.3	47	0.2758	0.01	0.011	0.057	0.051	-0.03	0.05

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.998768 Pr < W
Kolmogorov-Smirnov	D	0.015711 Pr > D
Cramer-von Mises	W-Sq	0.038351 Pr > W-Sq
Anderson-Darling	A-Sq	0.31635 Pr > A-Sq

• Jam 24:00


The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.66733	0.0197	33.87	<.0001	1	y	0
NUM1	0.29398	0.005587	52.62	<.0001	0	t	0
NUM2	2680.4	5.05036	530.73	<.0001	0	D1	0
NUM3	2688.3	5.04257	533.12	<.0001	0	D2	0
NUM4	2688.1	5.04924	532.39	<.0001	0	D3	0
NUM5	2703.6	5.06273	534.02	<.0001	0	D4	0
NUM6	2684.7	5.06671	529.86	<.0001	0	D5	0
NUM7	2640.1	5.05783	521.99	<.0001	0	D6	0
NUM8	2560.8	5.05348	506.74	<.0001	0	D7	0
NUM9	-431.669	12.57321	-34.33	<.0001	0	DV1	0
NUM10	-230.594	11.33573	-20.34	<.0001	0	DV2	0
NUM11	-267.518	14.51208	-18.43	<.0001	0	DV3	0
NUM12	-235.676	12.5634	-18.76	<.0001	0	DV4	0
NUM13	-165.683	12.67127	-13.08	<.0001	0	DV5	0
NUM14	-216.811	17.76941	-12.2	<.0001	0	DV6	0
NUM15	21.18061	12.68683	1.67	0.0952	0	DV7	0
NUM16	-76.3989	14.54886	-5.25	<.0001	0	DV8	0
NUM17	-63.084	12.647	-4.99	<.0001	0	DV9	0
NUM18	-200.347	14.52292	-13.8	<.0001	0	DV10	0
NUM19	-170.743	15.1127	-11.3	<.0001	0	DV11	0
NUM20	-188.472	18.16681	-10.37	<.0001	0	DV12	0
NUM21	-348.788	19.34361	-18.03	<.0001	0	DV13	0
NUM22	-652.326	19.76569	-33	<.0001	0	DV14	0
NUM23	-489.291	19.7652	-24.76	<.0001	0	DV15	0
NUM24	-560.491	19.34242	-28.98	<.0001	0	DV16	0
NUM25	-482.673	18.16527	-26.57	<.0001	0	DV17	0
NUM26	-350.561	15.11163	-23.2	<.0001	0	DV18	0
NUM27	-100.483	14.51343	-6.92	<.0001	0	DV19	0
NUM28	-52.2043	14.51215	-3.6	0.0003	0	DV20	0
NUM29	-110.946	14.60478	-7.6	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.03	5	0.4118	0.031	-0.017	-0.026	0.008	-0.038	0.003
12	16.32	11	0.1298	-0.038	-0.035	0.058	0.008	-0.002	-0.039
18	25.93	17	0.0757	0.036	-0.045	0.036	0.026	0.004	-0.034
24	31.39	23	0.1134	0.018	-0.008	0.017	0.042	-0.017	-0.032
30	35.96	29	0.1747	-0.022	-0.031	0.031	-0.006	0.022	-0.013
36	39.16	35	0.2883	0.004	0.01	-0.012	-0.033	-0.02	-0.019
42	44.94	41	0.3104	-0.006	-0.001	-0.005	-0.013	-0.034	0.049
48	56.07	47	0.1713	0	-0.055	-0.01	0.046	0.045	0.011


Test	Tests for Normality			
	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.999134	Pr < W	0.7432
Kolmogorov-Smirnov	D	0.011383	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.021154	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.166852	Pr > A-Sq	>0.2500

## Lampiran 2 Arsitektur DNN Data Simulasi Skenario 1


- 04:00




- 08:00



- 12:00




- 16:00






### Lampiran 3 Arsitektur Hibrida ARIMAX-DNN Data Simulasi Skenario 1

- 04:00




- 08:00








- 12:00



- 16:00





## Lampiran 4 Hasil ARIMAX pada Skenario 2

- Jam 04:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.26496	0.02599	10.2	<.0001	1	y	0
AR1,2	0.21221	0.02595	8.18	<.0001	2	y	0
NUM1	0.30085	0.01083	27.77	<.0001	0	t	0
NUM2	2410.8	10.63228	226.74	<.0001	0	D1	0
NUM3	2518.8	10.61895	237.2	<.0001	0	D2	0
NUM4	2531	10.61824	238.37	<.0001	0	D3	0
NUM5	2542.6	10.67259	238.24	<.0001	0	D4	0
NUM6	2550	10.67959	238.77	<.0001	0	D5	0
NUM7	2500.4	10.6331	235.15	<.0001	0	D6	0
NUM8	2445.5	10.6209	230.26	<.0001	0	D7	0
NUM9	-529.161	43.47876	-12.17	<.0001	0	DV1	0
NUM10	-266.509	38.95623	-6.84	<.0001	0	DV2	0
NUM11	-302.539	50.21086	-6.03	<.0001	0	DV3	0
NUM12	-281.797	43.4318	-6.49	<.0001	0	DV4	0
NUM13	-162.491	43.83062	-3.71	0.0002	0	DV5	0
NUM14	-185.651	61.52273	-3.02	0.0026	0	DV6	0
NUM15	-61.9731	44.05703	-1.41	0.1597	0	DV7	0
NUM16	-185.209	50.27038	-3.68	0.0002	0	DV8	0
NUM17	-225.858	43.88799	-5.15	<.0001	0	DV9	0
NUM18	-152.902	50.16203	-3.05	0.0023	0	DV10	0
NUM19	20.57892	45.91458	0.45	0.6541	0	DV11	0
NUM20	142.846	47.49315	3.01	0.0027	0	DV12	0
NUM21	-160.813	49.23755	-3.27	0.0011	0	DV13	0
NUM22	-452.58	49.55516	-9.13	<.0001	0	DV14	0
NUM23	-693.363	49.5553	-13.99	<.0001	0	DV15	0
NUM24	-727.786	49.2355	-14.78	<.0001	0	DV16	0
NUM25	-722.266	47.49302	-15.21	<.0001	0	DV17	0
NUM26	-742.868	45.89423	-16.19	<.0001	0	DV18	0
NUM27	-138.905	50.21818	-2.77	0.0057	0	DV19	0
NUM28	-35.6186	50.18545	-0.71	0.478	0	DV20	0
NUM29	-305.745	50.22454	-6.09	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.72	4	0.3173	0.005	-0.002	-0.027	0.047	-0.013	-0.01
12	9.02	10	0.5304	0.005	-0.027	-0.017	-0.017	-0.011	-0.039
18	17.07	16	0.3812	-0.008	-0.028	0.007	-0.067	0.008	-0.003
24	21.83	22	0.4703	0.012	0.024	-0.04	-0.03	0.004	0.002
30	25.25	28	0.6144	-0.006	0.015	-0.034	-0.016	-0.015	0.019
36	36.99	34	0.3325	-0.035	0.064	0.002	-0.047	0.001	-0.018
42	42.46	40	0.3657	-0.007	-0.006	-0.009	-0.033	-0.04	-0.027

48      53.35      46      0.2127      0.049      -0.034      -0.019      -0.02      0.05      0.021

Test	Tests for Normality			
	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.995543	Pr < W	0.0003
Kolmogorov-Smirnov	D	0.020194	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.161244	Pr > W-Sq	0.0184
Anderson-Darling	A-Sq	1.142025	Pr > A-Sq	0.0057

# - Jam 08:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.28142	0.02624	-10.73	<.0001	1	y	0
MA1,2	0.23404	0.07828	2.99	0.0028	2	y	0
AR1,1	0.43264	0.07593	5.7	<.0001	2	y	0
NUM1	0.27923	0.0105	26.59	<.0001	0	t	0
NUM2	2678.1	10.42728	256.83	<.0001	0	D1	0
NUM3	2728.8	10.41426	262.03	<.0001	0	D2	0
NUM4	2731.9	10.41336	262.34	<.0001	0	D3	0
NUM5	2718.6	10.46752	259.71	<.0001	0	D4	0
NUM6	2701.7	10.47435	257.93	<.0001	0	D5	0
NUM7	2598.8	10.42635	249.26	<.0001	0	D6	0
NUM8	2375.3	10.41515	228.06	<.0001	0	D7	0
NUM9	-616.871	44.07717	-14	<.0001	0	DV1	0
NUM10	-250.57	39.51958	-6.34	<.0001	0	DV2	0
NUM11	-262.92	50.89641	-5.17	<.0001	0	DV3	0
NUM12	-512.754	44.06413	-11.64	<.0001	0	DV4	0
NUM13	-371.021	44.42546	-8.35	<.0001	0	DV5	0
NUM14	-540.653	62.29045	-8.68	<.0001	0	DV6	0
NUM15	-215.202	44.45077	-4.84	<.0001	0	DV7	0
NUM16	-317.563	50.95822	-6.23	<.0001	0	DV8	0
NUM17	-256.472	44.30327	-5.79	<.0001	0	DV9	0
NUM18	-664.828	50.88289	-13.07	<.0001	0	DV10	0
NUM19	-707.491	46.16429	-15.33	<.0001	0	DV11	0
NUM20	-689.073	47.92012	-14.38	<.0001	0	DV12	0
NUM21	-1049.4	48.76872	-21.52	<.0001	0	DV13	0
NUM22	-1139.4	49.0329	-23.24	<.0001	0	DV14	0
NUM23	-735.16	49.03098	-14.99	<.0001	0	DV15	0
NUM24	-768.556	48.75666	-15.76	<.0001	0	DV16	0
NUM25	-736.546	47.89918	-15.38	<.0001	0	DV17	0
NUM26	-647.282	46.09561	-14.04	<.0001	0	DV18	0
NUM27	-847.692	50.94065	-16.64	<.0001	0	DV19	0
NUM28	-453.425	50.92601	-8.9	<.0001	0	DV20	0
NUM29	-406.027	50.97248	-7.97	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	4.77	3	0.1891	-0.007	0.02	0.014	-0.041	0.014	-0.028
12	9.94	9	0.3551	0.003	0.027	-0.03	0.024	-0.011	0.035
18	15.44	15	0.4204	0.029	0.002	0.013	-0.044	-0.014	0.024
24	18.87	21	0.5937	0	0.007	0.004	0.033	-0.027	-0.022
30	25.69	27	0.5356	0.011	0.007	0.023	0.003	-0.057	-0.024
36	29.42	33	0.6462	0.021	0.021	-0.002	-0.015	0.035	-0.012
42	31.89	39	0.7834	-0.007	-0.022	0.021	0.019	0.016	-0.007
48	35.59	45	0.8413	-0.033	-0.006	-0.022	0.003	0.022	-0.018

Tests for Normality				
Test	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.993646	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.022805	Pr > D	0.0652
Cramer-von Mises	W-Sq	0.21359	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.681594	Pr > A-Sq	<0.0050

- Jam 12:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.27347	0.02651	-10.31	<.0001	1	y	0
MA1,2	-0.20819	0.02736	-7.61	<.0001	2	y	0
MA1,3	-0.08511	0.02752	-3.09	0.002	3	y	0
MA1,4	-0.06715	0.02656	-2.53	0.0116	4	y	0
NUM1	0.31714	0.009382	33.8	<.0001	0	t	0
NUM2	2845.1	9.7088	293.04	<.0001	0	D1	0
NUM3	2872.3	9.69712	296.2	<.0001	0	D2	0
NUM4	2856.5	9.69512	294.64	<.0001	0	D3	0
NUM5	2840.5	9.75369	291.23	<.0001	0	D4	0
NUM6	2760.4	9.76028	282.82	<.0001	0	D5	0
NUM7	2760.5	9.70825	284.34	<.0001	0	D6	0
NUM8	2443.7	9.69583	252.04	<.0001	0	D7	0
NUM9	-694.509	44.43872	-15.63	<.0001	0	DV1	0
NUM10	-415.133	39.87129	-10.41	<.0001	0	DV2	0
NUM11	-336.075	51.38457	-6.54	<.0001	0	DV3	0
NUM12	-435.562	44.42409	-9.8	<.0001	0	DV4	0
NUM13	-391.985	44.85595	-8.74	<.0001	0	DV5	0
NUM14	-342.904	62.85296	-5.46	<.0001	0	DV6	0
NUM15	-200.664	44.93785	-4.47	<.0001	0	DV7	0
NUM16	-217.747	51.45116	-4.23	<.0001	0	DV8	0
NUM17	-196.657	44.71321	-4.4	<.0001	0	DV9	0
NUM18	-442.789	51.37682	-8.62	<.0001	0	DV10	0
NUM19	-579.712	46.47857	-12.47	<.0001	0	DV11	0

NUM20	-607.803	48.20957	-12.61	<.0001	0	DV12	0
NUM21	-983.245	49.18343	-19.99	<.0001	0	DV13	0
NUM22	-1121.4	49.35648	-22.72	<.0001	0	DV14	0
NUM23	-773.081	49.35416	-15.66	<.0001	0	DV15	0
NUM24	-888.041	49.18016	-18.06	<.0001	0	DV16	0
NUM25	-715.053	48.1909	-14.84	<.0001	0	DV17	0
NUM26	-661.167	46.45731	-14.23	<.0001	0	DV18	0
NUM27	-412.617	51.30945	-8.04	<.0001	0	DV19	0
NUM28	-310.468	51.35988	-6.04	<.0001	0	DV20	0
NUM29	-420.101	51.40296	-8.17	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	2.07	2	0.3551	0.003	0.002	0.006	0.006	0.031	-0.019
12	4.31	8	0.8284	-0.015	-0.002	0.001	-0.009	-0.034	-0.006
18	8.6	14	0.856	0.012	-0.011	0.043	0.026	0.001	-0.011
24	14.88	20	0.7831	-0.027	-0.02	-0.023	-0.033	-0.026	-0.028
30	21.04	26	0.7397	-0.004	-0.02	-0.018	0.017	-0.006	0.055
36	27.91	32	0.6738	0.015	0.034	-0.019	-0.018	-0.034	-0.037
42	31.92	38	0.7458	0.032	0.028	0.021	0.018	0.008	0.002
48	37.92	44	0.7287	-0.016	0.038	0.033	0.028	0.004	-0.02

Tests for Normality				
Test	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.994121	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.022799	Pr > D	0.0653
Cramer-von Mises	W-Sq	0.23137	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.705565	Pr > A-Sq	<0.0050

## • Jam 16:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.16667	0.02708	-6.15	<.0001	2	y	0
AR1,1	0.28537	0.02635	10.83	<.0001	1	y	0
NUM1	0.31074	0.009304	33.4	<.0001	0	t	0
NUM2	2968.6	9.67246	306.91	<.0001	0	D1	0
NUM3	2993.2	9.6604	309.84	<.0001	0	D2	0
NUM4	2955.4	9.6587	305.98	<.0001	0	D3	0
NUM5	2952.9	9.71732	303.88	<.0001	0	D4	0
NUM6	2930.5	9.72335	301.39	<.0001	0	D5	0
NUM7	2764	9.6733	285.73	<.0001	0	D6	0
NUM8	2547.4	9.6607	263.68	<.0001	0	D7	0
NUM9	-812.73	43.71524	-18.59	<.0001	0	DV1	0
NUM10	-412.44	39.25414	-10.51	<.0001	0	DV2	0

NUM11	-467.367	50.47985	-9.26	<.0001	0	DV3	0
NUM12	-489.427	43.68425	-11.2	<.0001	0	DV4	0
NUM13	-340.944	44.04498	-7.74	<.0001	0	DV5	0
NUM14	-491.265	61.80142	-7.95	<.0001	0	DV6	0
NUM15	-246.156	44.2781	-5.56	<.0001	0	DV7	0
NUM16	-385.648	50.60901	-7.62	<.0001	0	DV8	0
NUM17	-319.929	44.12947	-7.25	<.0001	0	DV9	0
NUM18	-589.765	50.52422	-11.67	<.0001	0	DV10	0
NUM19	-412.457	46.11354	-8.94	<.0001	0	DV11	0
NUM20	-557.579	47.98358	-11.62	<.0001	0	DV12	0
NUM21	-813.656	49.35521	-16.49	<.0001	0	DV13	0
NUM22	-1185	49.47327	-23.95	<.0001	0	DV14	0
NUM23	-924.798	49.47312	-18.69	<.0001	0	DV15	0
NUM24	-1033.9	49.35386	-20.95	<.0001	0	DV16	0
NUM25	-885.621	47.97628	-18.46	<.0001	0	DV17	0
NUM26	-812.313	46.10482	-17.62	<.0001	0	DV18	0
NUM27	-519.049	50.46215	-10.29	<.0001	0	DV19	0
NUM28	-407.215	50.47999	-8.07	<.0001	0	DV20	0
NUM29	-508.681	50.54376	-10.06	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	4.58	4	0.3331	-0.003	-0.001	0.045	-0.012	0.017	-0.025
12	12.55	10	0.2497	-0.029	0.023	-0.058	-0.02	0.016	-0.004
18	15.06	16	0.5205	-0.008	0.025	-0.004	0.028	0.009	0.013
24	21.47	22	0.4921	-0.018	0.044	0	0.008	-0.026	0.036
30	28.96	28	0.4145	-0.033	-0.004	0.03	0.014	-0.042	-0.032
36	37.11	34	0.3274	0	-0.004	-0.057	-0.014	0.029	-0.033
42	39.14	40	0.5088	0	0.019	0.015	0.027	0.003	-0.005
48	41.02	46	0.6806	0.01	-0.014	-0.017	0.001	0.021	0.014

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W 0.993527	Pr < W <0.0001
Kolmogorov-Smirnov	D 0.020184	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.166306	Pr > W-Sq 0.0158
Anderson-Darling	A-Sq 1.343935	Pr > A-Sq <0.0050

## • Jam 20:00

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.3755	0.07024	5.35	<.0001	1	y	0
AR1,1	0.6424	0.0581	11.06	<.0001	1	y	0

NUM1	0.31695	0.01033	30.67	<.0001	0	t	0
NUM2	3528.9	10.44792	337.76	<.0001	0	D1	0
NUM3	3543.9	10.43513	339.62	<.0001	0	D2	0
NUM4	3554.7	10.43317	340.71	<.0001	0	D3	0
NUM5	3541.7	10.49104	337.59	<.0001	0	D4	0
NUM6	3484.5	10.49775	331.93	<.0001	0	D5	0
NUM7	3428.7	10.44578	328.24	<.0001	0	D6	0
NUM8	3332.3	10.43427	319.36	<.0001	0	D7	0
NUM9	-452.377	46.06074	-9.82	<.0001	0	DV1	0
NUM10	-280.859	41.28312	-6.8	<.0001	0	DV2	0
NUM11	-306.173	53.1874	-5.76	<.0001	0	DV3	0
NUM12	-242.279	46.01766	-5.26	<.0001	0	DV4	0
NUM13	-136.588	46.39331	-2.94	0.0033	0	DV5	0
NUM14	-246.421	65.17377	-3.78	0.0002	0	DV6	0
NUM15	-14.8849	46.39747	-0.32	0.7484	0	DV7	0
NUM16	-33.3284	53.25941	-0.63	0.5316	0	DV8	0
NUM17	-84.5291	46.26364	-1.83	0.0679	0	DV9	0
NUM18	-240.813	53.16437	-4.53	<.0001	0	DV10	0
NUM19	-351	48.00062	-7.31	<.0001	0	DV11	0
NUM20	-344.265	49.70084	-6.93	<.0001	0	DV12	0
NUM21	-652.663	50.38134	-12.95	<.0001	0	DV13	0
NUM22	-881.517	50.60315	-17.42	<.0001	0	DV14	0
NUM23	-682.712	50.57864	-13.5	<.0001	0	DV15	0
NUM24	-658.114	50.31776	-13.08	<.0001	0	DV16	0
NUM25	-574.494	49.62794	-11.58	<.0001	0	DV17	0
NUM26	-411.197	47.92431	-8.58	<.0001	0	DV18	0
NUM27	-147.785	53.20144	-2.78	0.0055	0	DV19	0
NUM28	-198.661	53.1509	-3.74	0.0002	0	DV20	0
NUM29	-99.4362	53.24093	-1.87	0.062	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	4.84	4	0.3043	-0.011	0.042	-0.03	0.002	-0.018	-0.013	
12	7.81	10	0.6471	0.02	-0.027	0.017	0.005	-0.012	-0.02	
18	12.15	16	0.7339	-0.005	-0.004	0.017	0.016	-0.025	-0.041	
24	15.84	22	0.8239	-0.005	-0.034	-0.008	-0.031	-0.007	-0.015	
30	19.59	28	0.8791	-0.005	0.013	0.019	-0.037	-0.008	-0.024	
36	23.28	34	0.9172	0.032	-0.001	0.006	0.003	-0.036	-0.01	
42	24.45	40	0.9749	0.01	0.001	-0.004	-0.017	-0.007	0.017	
48	38.32	46	0.7821	0.016	0.02	-0.026	0.063	0.03	0.055	

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W 0.003292	Pr < W <0.0001
Kolmogorov-Smirnov	D 0.022392	Pr > D 0.0756
Cramer-von Mises	W-Sq 0.188057	Pr > W-Sq 0.0078
Anderson-Darling	A-Sq 1.62687	Pr > A-Sq <0.0050



• Jam 24:00


The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.28368	0.0264	-10.74	<.0001	1	y	0
AR1,1	0.21826	0.02683	8.13	<.0001	2	y	0
NUM1	0.28935	0.009459	30.59	<.0001	0	t	0
NUM2	2685.3	9.79104	274.26	<.0001	0	D1	0
NUM3	2704.8	9.77891	276.59	<.0001	0	D2	0
NUM4	2698	9.77736	275.94	<.0001	0	D3	0
NUM5	2707.5	9.83579	275.27	<.0001	0	D4	0
NUM6	2686.5	9.8417	272.97	<.0001	0	D5	0
NUM7	2642.9	9.79087	269.94	<.0001	0	D6	0
NUM8	2563.3	9.77867	262.13	<.0001	0	D7	0
NUM9	-441.41	44.44813	-9.93	<.0001	0	DV1	0
NUM10	-235.703	39.82952	-5.92	<.0001	0	DV2	0
NUM11	-243.372	51.3074	-4.74	<.0001	0	DV3	0
NUM12	-241.818	44.39884	-5.45	<.0001	0	DV4	0
NUM13	-138.651	44.76966	-3.1	0.002	0	DV5	0
NUM14	-302.81	62.80273	-4.82	<.0001	0	DV6	0
NUM15	47.714	44.9024	1.06	0.2881	0	DV7	0
NUM16	-71.3246	51.36335	-1.39	0.1652	0	DV8	0
NUM17	-93.7978	44.74435	-2.1	0.0362	0	DV9	0
NUM18	-273.094	51.30216	-5.32	<.0001	0	DV10	0
NUM19	-119.314	46.61347	-2.56	0.0106	0	DV11	0
NUM20	-159.378	48.48431	-3.29	0.001	0	DV12	0
NUM21	-291.081	49.56262	-5.87	<.0001	0	DV13	0
NUM22	-536.536	49.65184	-10.81	<.0001	0	DV14	0
NUM23	-459.549	49.65108	-9.26	<.0001	0	DV15	0
NUM24	-586.916	49.56175	-11.84	<.0001	0	DV16	0
NUM25	-457.491	48.48001	-9.44	<.0001	0	DV17	0
NUM26	-399.994	46.6104	-8.58	<.0001	0	DV18	0
NUM27	-81.1928	51.28622	-1.58	0.1136	0	DV19	0
NUM28	-16.7414	51.33435	-0.33	0.7444	0	DV20	0
NUM29	-72.4961	51.34045	-1.41	0.1581	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.55	4	0.8185	-0.003	-0.002	0.03	0.011	-0.006	0.001
12	4.41	10	0.9268	-0.011	0.004	0.017	0.018	0.027	-0.023
18	6.28	16	0.9847	-0.007	-0.008	-0.012	-0.017	-0.022	-0.016
24	12.67	22	0.9421	0.019	-0.025	0	-0.021	-0.024	0.048
30	16.88	28	0.951	-0.024	0.013	0.014	-0.043	0.002	0.001
36	24.6	34	0.8816	-0.029	0.011	0.047	0.017	0.038	0.016
42	27.84	40	0.9267	0.024	-0.012	0.032	0.009	0.011	0.015
48	36.08	46	0.8528	-0.031	-0.049	0.003	0.032	0.024	0.021


Tests for Normality				
Test	---Statistic---		-----p Value-----	
Shapiro-Wilk	W	0.992801	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.022789	Pr > D	0.0656
Cramer-von Mises	W-Sq	0.245197	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.874848	Pr > A-Sq	<0.0050

## Lampiran 5 Arsitektur DNN Data Simulasi Skenario 2


- 04:00




- 08:00




- 12:00




- 16:00



- 20:00




- 24:00




## Lampiran 6 Arsitektur Hibrida ARIMAX-DNN Data Simulasi Skenario 2


- 04:00




- 08:00




- 12:00




- 16:00



- 20:00



- 24:00





**Lampiran 7** Hasil Perhitungan RMSEP Horizon untuk Data Simulasi

Skenario	Jam	Model	Short	Medium	Long	Average
1	04:00	ARIMAX	36,14	44,39	42,36	40,96
		DNN	31,81	52,16	48,95	44,31
		Hibrida	36,00	44,21	42,22	40,81
	08:00	ARIMAX	22,06	46,18	44,51	37,58
		DNN	18,86	46,91	45,29	37,02
		Hibrida	22,33	45,88	44,30	37,50
	12:00	ARIMAX	52,16	47,30	44,86	48,11
		DNN	68,31	51,87	48,10	56,09
		Hibrida	52,27	47,26	44,84	48,12
	16:00	ARIMAX	14,61	44,41	43,33	34,12
		DNN	28,01	44,51	47,16	39,89
		Hibrida	14,68	44,35	43,29	34,11
	20:00	ARIMAX	41,68	35,63	37,79	38,37
		DNN	47,40	39,44	41,04	42,63
		Hibrida	41,74	35,46	37,64	38,28
	24:00	ARIMAX	30,99	33,87	41,80	35,55
		DNN	32,66	38,13	42,13	37,64
		Hibrida	31,29	33,89	41,63	35,60
2	04:00	ARIMAX	86,35	94,73	96,42	92,50
		DNN	97,73	96,59	97,44	97,25
		Hibrida	83,40	93,63	95,94	90,99
	08:00	ARIMAX	98,28	100,15	100,55	99,66
		DNN	97,17	99,63	100,56	99,12
		Hibrida	98,44	99,58	100,04	99,35
	12:00	ARIMAX	110,16	103,64	102,82	105,54
		DNN	114,41	104,28	103,45	107,38
		Hibrida	107,48	102,71	102,42	104,20
	16:00	ARIMAX	79,64	99,67	99,05	92,79
		DNN	82,23	100,83	103,01	95,36
		Hibrida	83,20	99,13	98,92	93,75
	20:00	ARIMAX	106,85	97,38	101,56	101,93
		DNN	110,09	97,52	100,01	102,54
		Hibrida	106,85	97,38	100,87	101,70
	24:00	ARIMAX	79,94	97,76	98,89	92,20
		DNN	101,4	125,22	121,88	116,17
		Hibrida	80,07	97,62	98,71	92,13

Lampiran 8 Hasil ARIMAX pada Data Beban Listrik

- Jam 00:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.64831	0.02228	29.1	<.0001	1	y	0
AR1,2	0.07937	0.02826	2.81	0.005	3	y	0
AR1,3	0.05509	0.02772	1.99	0.0471	4	y	0
AR1,4	0.05595	0.02123	2.64	0.0085	7	y	0
AR1,5	0.05649	0.01807	3.13	0.0018	18	y	0
NUM1	0.38144	0.03649	10.45	<.0001	0	t	0
NUM2	2142.5	30.75008	69.68	<.0001	0	D1	0
NUM3	2263.2	30.69833	73.72	<.0001	0	D2	0
NUM4	2268.5	30.75018	73.77	<.0001	0	D3	0
NUM5	2269.3	30.7773	73.73	<.0001	0	D4	0
NUM6	2275.7	30.78755	73.92	<.0001	0	D5	0
NUM7	2265.5	30.77865	73.61	<.0001	0	D6	0
NUM8	2219.8	30.77665	72.13	<.0001	0	D7	0
NUM9	22.80941	29.03964	0.79	0.4323	0	DV1	0
NUM10	72.6473	25.96856	2.8	0.0052	0	DV2	0
NUM11	84.49856	33.23283	2.54	0.0111	0	DV3	0
NUM12	-4.14475	28.76935	-0.14	0.8855	0	DV4	0
NUM13	62.14173	29.00215	2.14	0.0323	0	DV5	0
NUM14	104.1839	40.69325	2.56	0.0106	0	DV6	0
NUM15	41.53347	28.98389	1.43	0.1521	0	DV7	0
NUM16	28.97067	33.30383	0.87	0.3845	0	DV8	0
NUM17	3.11024	28.89563	0.11	0.9143	0	DV9	0
NUM18	96.27696	33.29407	2.89	0.0039	0	DV10	0
NUM19	5.34937	33.99733	0.16	0.875	0	DV11	0
NUM20	-33.8581	39.86867	-0.85	0.3959	0	DV12	0
NUM21	-218.523	41.68711	-5.24	<.0001	0	DV13	0
NUM22	-325.652	42.35223	-7.69	<.0001	0	DV14	0
NUM23	-605.205	42.32196	-14.3	<.0001	0	DV15	0
NUM24	-529.968	41.64655	-12.73	<.0001	0	DV16	0
NUM25	-423.159	39.87608	-10.61	<.0001	0	DV17	0
NUM26	-305.519	33.98701	-8.99	<.0001	0	DV18	0
NUM27	80.8935	33.25008	2.43	0.0151	0	DV19	0
NUM28	53.67118	33.27633	1.61	0.107	0	DV20	0
NUM29	17.74029	33.44878	0.53	0.5959	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.01	1	0.0829	-0.01	0.019	0.002	-0.014	0.032	-0.019
12	7.3	7	0.3985	0.015	-0.027	-0.009	-0.03	-0.006	0.03
18	17.76	13	0.1669	0.012	0.054	-0.027	0.047	-0.031	0.012
24	20.03	19	0.3929	-0.009	-0.009	-0.015	0.031	-0.01	-0.008

30	26.34	25	0.3895	-0.038	-0.002	0.001	-0.004	-0.048	0.022
36	31.94	31	0.4196	0.044	-0.022	-0.02	-0.022	0.007	0.018
42	34.76	37	0.5744	-0.011	0.038	0.007	-0.001	0.005	0.016
48	45.44	43	0.3705	-0.005	0.023	-0.025	0.075	-0.015	0.005

Tests for Normality				
Test	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.956654	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.081719	Pr > D	<0.0100
Cramer-von Mises	W-Sq	2.734788	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	16.55311	Pr > A-Sq	<0.0050

- Jam 01:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.68957	0.02174	31.72	<.0001	1	y	0
AR1,2	0.10411	0.02304	4.52	<.0001	3	y	0
AR1,3	0.07231	0.01955	3.7	0.0002	7	y	0
NUM1	0.36058	0.02893	12.46	<.0001	0	t	0
NUM2	2125.1	24.56056	86.53	<.0001	0	D1	0
NUM3	2250.1	24.51959	91.77	<.0001	0	D2	0
NUM4	2249.2	24.56286	91.57	<.0001	0	D3	0
NUM5	2253.3	24.5915	91.63	<.0001	0	D4	0
NUM6	2257.8	24.60734	91.75	<.0001	0	D5	0
NUM7	2246	24.59325	91.33	<.0001	0	D6	0
NUM8	2196.8	24.5849	89.36	<.0001	0	D7	0
NUM9	0.1494	27.37477	0.01	0.9956	0	DV1	0
NUM10	46.62461	24.4958	1.9	0.0572	0	DV2	0
NUM11	86.64694	31.35657	2.76	0.0058	0	DV3	0
NUM12	5.17554	27.16239	0.19	0.8489	0	DV4	0
NUM13	71.67741	27.37084	2.62	0.0089	0	DV5	0
NUM14	122.2021	38.41529	3.18	0.0015	0	DV6	0
NUM15	38.29328	27.35311	1.4	0.1617	0	DV7	0
NUM16	18.70788	31.4325	0.6	0.5518	0	DV8	0
NUM17	-12.3774	27.258	-0.45	0.6498	0	DV9	0
NUM18	94.38051	31.43016	3	0.0027	0	DV10	0
NUM19	1.26065	32.72964	0.04	0.9693	0	DV11	0
NUM20	-45.1923	39.08555	-1.16	0.2478	0	DV12	0
NUM21	-226.339	41.35937	-5.47	<.0001	0	DV13	0
NUM22	-351.038	42.55407	-8.25	<.0001	0	DV14	0
NUM23	-596.89	42.5184	-14.04	<.0001	0	DV15	0
NUM24	-515.645	41.27779	-12.49	<.0001	0	DV16	0
NUM25	-402.196	39.05064	-10.3	<.0001	0	DV17	0
NUM26	-285.726	32.69479	-8.74	<.0001	0	DV18	0
NUM27	31.6434	31.38969	1.01	0.3136	0	DV19	0

NUM28	64.57683	31.35872	2.06	0.0396	0	DV20	0
NUM29	30.36945	31.59238	0.96	0.3366	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.43	3	0.1426	-0.001	-0.011	-0.035	0.012	0.045	-0.011
12	11.23	9	0.2603	0.004	-0.046	0.002	-0.037	-0.017	0.012
18	22.28	15	0.1006	0.017	0.034	-0.022	0.036	-0.025	0.06
24	26.79	21	0.178	0.019	0.014	0.006	0.048	0.01	0.003
30	31.43	27	0.2539	-0.013	0.005	0	0.014	-0.045	0.025
36	36.49	33	0.3098	0.037	-0.022	-0.005	-0.034	0.004	0.018
42	41.64	39	0.3564	-0.005	0.039	0.029	0.008	0.012	0.029
48	46.23	45	0.4215	0.005	0.019	0.007	0.051	-0.001	0.004

Tests for Normality				
Test	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.957943	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.073401	Pr > D	<0.0100
Cramer-von Mises	W-Sq	2.790137	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	16.60643	Pr > A-Sq	<0.0050

- Jam 01:30

The ARIMA Procedure Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.68763	0.02168	31.72	<.0001	1	y	0
AR1,2	0.11328	0.02298	4.93	<.0001	3	y	0
AR1,3	0.06558	0.01954	3.36	0.0008	7	y	0
NUM1	0.35577	0.02894	12.3	<.0001	0	t	0
NUM2	2094.4	24.55662	85.29	<.0001	0	D1	0
NUM3	2220.9	24.5157	90.59	<.0001	0	D2	0
NUM4	2223.7	24.55812	90.55	<.0001	0	D3	0
NUM5	2227.1	24.58546	90.59	<.0001	0	D4	0
NUM6	2227.9	24.60091	90.56	<.0001	0	D5	0
NUM7	2215.8	24.58743	90.12	<.0001	0	D6	0
NUM8	2165.6	24.57998	88.11	<.0001	0	D7	0
NUM9	-16.431	27.25384	-0.6	0.5467	0	DV1	0
NUM10	32.58216	24.40986	1.33	0.1822	0	DV2	0
NUM11	88.59203	31.25042	2.83	0.0046	0	DV3	0
NUM12	6.72481	27.06503	0.25	0.8038	0	DV4	0
NUM13	58.84615	27.27992	2.16	0.0312	0	DV5	0
NUM14	123.0113	38.2801	3.21	0.0013	0	DV6	0
NUM15	50.23416	27.25263	1.84	0.0655	0	DV7	0
NUM16	-9.32976	31.32439	-0.3	0.7659	0	DV8	0
NUM17	-8.14829	27.15938	-0.3	0.7642	0	DV9	0

NUM18	80.06714	31.32555	2.56	0.0107	0	DV10	0
NUM19	0.30945	32.6048	0.01	0.9924	0	DV11	0
NUM20	-46.6819	38.89138	-1.2	0.2302	0	DV12	0
NUM21	-231.863	41.10778	-5.64	<.0001	0	DV13	0
NUM22	-364.382	42.32213	-8.61	<.0001	0	DV14	0
NUM23	-587.456	42.28041	-13.89	<.0001	0	DV15	0
NUM24	-506.954	41.02017	-12.36	<.0001	0	DV16	0
NUM25	-404.21	38.86035	-10.4	<.0001	0	DV17	0
NUM26	-276.842	32.57074	-8.5	<.0001	0	DV18	0
NUM27	20.56866	31.2789	0.66	0.5109	0	DV19	0
NUM28	75.0812	31.24834	2.4	0.0164	0	DV20	0
NUM29	16.94332	31.47975	0.54	0.5905	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.08	3	0.1657	0.006	-0.022	-0.029	0.007	0.044	-0.01
12	11.32	9	0.2545	0.003	-0.033	-0.002	-0.045	-0.025	0.022
18	17.44	15	0.293	0.017	0.025	-0.017	0.023	-0.009	0.048
24	22.72	21	0.3591	0.021	0.024	0.004	0.046	-0.004	0.019
30	27.33	27	0.4462	-0.021	0.021	-0.012	0.01	-0.041	0.017
36	32.86	33	0.4743	0.039	-0.026	-0.001	-0.037	0.01	-0.001
42	37.93	39	0.5187	0.012	0.038	0.032	0.009	-0.003	0.025
48	45.6	45	0.4471	0.02	0.022	-0.007	0.064	-0.008	0.004

Tests for Normality			
Test	---Statistic---	-----p Value-----	
Shapiro-Wilk	W	0.95426	Pr < W <0.0001
Kolmogorov-Smirnov	D	0.077891	Pr > D <0.0100
Cramer-von Mises	W-Sq	3.116641	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	18.5622	Pr > A-Sq <0.0050

- Jam 02:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.70469	0.02154	32.71	<.0001	1	y	0
AR1,2	0.10992	0.02297	4.79	<.0001	3	y	0
AR1,3	0.0582	0.01919	3.03	0.0025	7	y	0
NUM1	0.35348	0.02962	11.93	<.0001	0	t	0
NUM2	2068.8	25.08551	82.47	<.0001	0	D1	0
NUM3	2193.3	25.04351	87.58	<.0001	0	D2	0
NUM4	2195.3	25.08698	87.51	<.0001	0	D3	0
NUM5	2198.6	25.11445	87.54	<.0001	0	D4	0
NUM6	2201.1	25.12998	87.59	<.0001	0	D5	0
NUM7	2187.1	25.11697	87.08	<.0001	0	D6	0

NUM8	2133.6	25.10951	84.97	<.0001	0	D7	0
NUM9	-19.1453	26.48358	-0.72	0.4699	0	DV1	0
NUM10	41.56847	23.70745	1.75	0.0797	0	DV2	0
NUM11	92.44361	30.34496	3.05	0.0024	0	DV3	0
NUM12	17.00784	26.27913	0.65	0.5176	0	DV4	0
NUM13	56.08334	26.49537	2.12	0.0345	0	DV5	0
NUM14	117.3216	37.17811	3.16	0.0016	0	DV6	0
NUM15	43.48629	26.47537	1.64	0.1007	0	DV7	0
NUM16	1.22122	30.41928	0.04	0.968	0	DV8	0
NUM17	-3.20602	26.37961	-0.12	0.9033	0	DV9	0
NUM18	77.32044	30.40911	2.54	0.0111	0	DV10	0
NUM19	8.86973	31.88721	0.28	0.7809	0	DV11	0
NUM20	-40.8232	38.3311	-1.07	0.287	0	DV12	0
NUM21	-227.356	40.67602	-5.59	<.0001	0	DV13	0
NUM22	-372.217	41.93535	-8.88	<.0001	0	DV14	0
NUM23	-577.939	41.90036	-13.79	<.0001	0	DV15	0
NUM24	-496.869	40.598	-12.24	<.0001	0	DV16	0
NUM25	-396.797	38.29905	-10.36	<.0001	0	DV17	0
NUM26	-274.088	31.8586	-8.6	<.0001	0	DV18	0
NUM27	22.87214	30.37339	0.75	0.4516	0	DV19	0
NUM28	63.74304	30.34819	2.1	0.0359	0	DV20	0
NUM29	20.56594	30.57296	0.67	0.5013	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	2.99	3	0.393	0.004	-0.016	-0.026	0.009	0.031	-0.007	
12	7.37	9	0.599	-0.006	-0.015	-0.012	-0.037	-0.03	0.018	
18	12.3	15	0.6559	0.027	0.01	-0.006	0.027	-0.011	0.04	
24	17.11	21	0.7047	0.023	0.027	0.002	0.044	-0.002	0.005	
30	22.14	27	0.7301	-0.024	0.031	-0.008	-0.001	-0.04	0.014	
36	30.32	33	0.6013	0.049	-0.031	-0.004	-0.043	0.015	0.005	
42	34.7	39	0.6663	0.006	0.035	0.028	0.009	0.02	0.018	
48	40.46	45	0.6643	0.008	0.021	-0.002	0.057	-0.006	0.004	

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.953138 Pr < W
Kolmogorov-Smirnov	D	0.077069 Pr > D
Cramer-von Mises	W-Sq	3.249285 Pr > W-Sq
Anderson-Darling	A-Sq	19.38322 Pr > A-Sq

- Jam 02:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.7671	0.02631	29.16	<.0001	1	y	0
AR1,2	-0.07096	0.03318	-2.14	0.0326	2	y	0
AR1,3	0.16477	0.02634	6.25	<.0001	3	y	0
NUM1	0.34491	0.02731	12.63	<.0001	0	t	0
NUM2	2057.4	23.15727	88.85	<.0001	0	D1	0
NUM3	2176.7	23.11859	94.15	<.0001	0	D2	0
NUM4	2180.6	23.1588	94.16	<.0001	0	D3	0
NUM5	2185.3	23.18087	94.27	<.0001	0	D4	0
NUM6	2183.7	23.19427	94.15	<.0001	0	D5	0
NUM7	2170.1	23.18303	93.61	<.0001	0	D6	0
NUM8	2117	23.17955	91.33	<.0001	0	D7	0
NUM9	-29.7926	25.42479	-1.17	0.2415	0	DV1	0
NUM10	35.63004	22.82534	1.56	0.1187	0	DV2	0
NUM11	77.82911	29.16145	2.67	0.0077	0	DV3	0
NUM12	19.18532	25.24398	0.76	0.4474	0	DV4	0
NUM13	63.36308	25.46631	2.49	0.013	0	DV5	0
NUM14	132.3281	35.70978	3.71	0.0002	0	DV6	0
NUM15	53.98948	25.3891	2.13	0.0336	0	DV7	0
NUM16	28.55644	29.23849	0.98	0.3289	0	DV8	0
NUM17	8.45611	25.28907	0.33	0.7381	0	DV9	0
NUM18	90.11137	29.21202	3.08	0.0021	0	DV10	0
NUM19	-2.76554	31.81167	-0.09	0.9307	0	DV11	0
NUM20	-34.7505	39.43845	-0.88	0.3784	0	DV12	0
NUM21	-212.475	41.65502	-5.1	<.0001	0	DV13	0
NUM22	-362.899	42.91873	-8.46	<.0001	0	DV14	0
NUM23	-558.285	42.86795	-13.02	<.0001	0	DV15	0
NUM24	-478.922	41.54567	-11.53	<.0001	0	DV16	0
NUM25	-386.919	39.32761	-9.84	<.0001	0	DV17	0
NUM26	-256.999	31.74339	-8.1	<.0001	0	DV18	0
NUM27	20.8426	29.16897	0.71	0.475	0	DV19	0
NUM28	70.70755	29.1609	2.42	0.0154	0	DV20	0
NUM29	35.71773	29.40295	1.21	0.2247	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.33	3	0.228	-0.009	-0.007	-0.051	-0.007	0.009	-0.01
12	10.8	9	0.29	0.042	0.014	0.004	-0.028	-0.012	0.038
18	16.48	15	0.3511	0.025	0.022	0.008	0.019	-0.009	0.047
24	22.4	21	0.3769	0.014	0.045	-0.003	0.042	0	0.007
30	26.19	27	0.5081	-0.015	0.028	-0.006	0.003	-0.033	0.021
36	33.3	33	0.4524	0.047	-0.021	-0.008	-0.046	0.002	0.001
42	39.83	39	0.4331	0.023	0.042	0.038	0.014	0.009	0.02

48    48.11    45    0.3479    0.012    0.005    -0.02    0.069    -0.011    -0.003

Test	Tests for Normality			
	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.952438	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.078339	Pr > D	<0.0100
Cramer-von Mises	W-Sq	3.134747	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	18.85386	Pr > A-Sq	<0.0050

- Jam 03:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.73766	0.02119	34.81	<.0001	1	y	0
AR1,2	0.11247	0.023	4.89	<.0001	3	y	0
AR1,3	0.04645	0.01853	2.51	0.0123	7	y	0
NUM1	0.3587	0.03595	9.98	<.0001	0	t	0
NUM2	2035.2	30.17388	67.45	<.0001	0	D1	0
NUM3	2148.6	30.12302	71.33	<.0001	0	D2	0
NUM4	2155.6	30.1754	71.44	<.0001	0	D3	0
NUM5	2162.8	30.20497	71.61	<.0001	0	D4	0
NUM6	2158.9	30.22366	71.43	<.0001	0	D5	0
NUM7	2142.8	30.21026	70.93	<.0001	0	D6	0
NUM8	2086.1	30.20249	69.07	<.0001	0	D7	0
NUM9	-36.2831	26.39696	-1.37	0.1695	0	DV1	0
NUM10	33.61952	23.56964	1.43	0.154	0	DV2	0
NUM11	67.3214	30.16232	2.23	0.0258	0	DV3	0
NUM12	9.31331	26.12562	0.36	0.7215	0	DV4	0
NUM13	63.11299	26.33456	2.4	0.0167	0	DV5	0
NUM14	120.5193	36.9511	3.26	0.0011	0	DV6	0
NUM15	40.69531	26.32042	1.55	0.1223	0	DV7	0
NUM16	41.08968	30.23764	1.36	0.1744	0	DV8	0
NUM17	1.44278	26.21944	0.06	0.9561	0	DV9	0
NUM18	85.60563	30.2326	2.83	0.0047	0	DV10	0
NUM19	19.3564	32.16231	0.6	0.5474	0	DV11	0
NUM20	-21.0695	39.1229	-0.54	0.5903	0	DV12	0
NUM21	-189.348	41.80258	-4.53	<.0001	0	DV13	0
NUM22	-383.671	43.21616	-8.88	<.0001	0	DV14	0
NUM23	-594.589	43.14522	-13.78	<.0001	0	DV15	0
NUM24	-500.805	41.65344	-12.02	<.0001	0	DV16	0
NUM25	-406.548	39.04366	-10.41	<.0001	0	DV17	0
NUM26	-280.705	32.08013	-8.75	<.0001	0	DV18	0
NUM27	12.36358	30.19368	0.41	0.6823	0	DV19	0
NUM28	48.6233	30.163	1.61	0.1072	0	DV20	0
NUM29	25.95962	30.38196	0.85	0.393	0	DV21	0



## Autocorrelation Check of Residuals

To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.93	3	0.269	0.01	-0.021	-0.026	0.015	0.033	-0.012
12	8.4	9	0.4939	0.001	-0.002	-0.018	-0.029	-0.033	0.028
18	11.35	15	0.7274	0.008	0.022	-0.011	0.007	-0.003	0.036
24	19.22	21	0.5711	0.004	0.053	-0.02	0.042	-0.014	0.013
30	25.52	27	0.5451	-0.03	0.023	-0.009	-0.011	-0.051	0.006
36	32.66	33	0.4838	0.02	-0.033	-0.03	-0.047	-0.014	0.007
42	41.2	39	0.3744	0.02	0.045	0.031	0.014	0.009	0.045
48	44.94	45	0.4745	0.004	0.018	-0.016	0.042	-0.009	0.005

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.936078 Pr < W <0.0001
Kolmogorov-Smirnov	D	0.088334 Pr > D <0.0100
Cramer-von Mises	W-Sq	3.897757 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	23.06774 Pr > A-Sq <0.0050

- Jam 03:30

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.79215	0.02051	38.62	<.0001	1	y	0
AR1,2	0.11847	0.0205	5.78	<.0001	3	y	0
NUM1	0.37402	0.04212	8.88	<.0001	0	t	0
NUM2	2034.2	35.02026	58.09	<.0001	0	D1	0
NUM3	2142.3	34.96069	61.28	<.0001	0	D2	0
NUM4	2149.1	35.01861	61.37	<.0001	0	D3	0
NUM5	2157.8	35.05049	61.56	<.0001	0	D4	0
NUM6	2149.9	35.0712	61.3	<.0001	0	D5	0
NUM7	2134.3	35.05761	60.88	<.0001	0	D6	0
NUM8	2075.5	35.05127	59.21	<.0001	0	D7	0
NUM9	-45.7761	26.50741	-1.73	0.0844	0	DV1	0
NUM10	34.23665	23.61499	1.45	0.1473	0	DV2	0
NUM11	70.17449	30.20291	2.32	0.0203	0	DV3	0
NUM12	6.62391	26.15806	0.25	0.8001	0	DV4	0
NUM13	54.49179	26.38654	2.07	0.0391	0	DV5	0
NUM14	111.3294	37.018	3.01	0.0027	0	DV6	0
NUM15	38.1515	26.36296	1.45	0.1481	0	DV7	0
NUM16	27.18891	30.28667	0.9	0.3695	0	DV8	0
NUM17	-2.90724	26.25876	-0.11	0.9119	0	DV9	0
NUM18	78.14759	30.27796	2.58	0.01	0	DV10	0
NUM19	31.98043	32.92911	0.97	0.3316	0	DV11	0
NUM20	10.2703	40.88545	0.25	0.8017	0	DV12	0
NUM21	-135.002	44.00128	-3.07	0.0022	0	DV13	0

NUM22	-366.571	45.69324	-8.02	<.0001	0	DV14	0
NUM23	-611.318	45.65458	-13.39	<.0001	0	DV15	0
NUM24	-503.161	43.92239	-11.46	<.0001	0	DV16	0
NUM25	-402.755	40.81268	-9.87	<.0001	0	DV17	0
NUM26	-271.572	32.8532	-8.27	<.0001	0	DV18	0
NUM27	16.38968	30.24912	0.54	0.588	0	DV19	0
NUM28	30.73455	30.20947	1.02	0.3091	0	DV20	0
NUM29	0.09827	30.42384	0	0.9974	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.24	4	0.2634	0.017	-0.031	-0.034	0.01	0.016	-0.028
12	7.69	10	0.6588	0.022	0.01	-0.009	-0.019	-0.014	0.021
18	12.13	16	0.7351	0.021	0.023	-0.013	0.009	-0.008	0.042
24	17.82	22	0.7164	0	0.053	-0.012	0.029	0.003	-0.002
30	23.94	28	0.6849	-0.019	0.021	-0.023	-0.012	-0.051	0.002
36	31.64	34	0.584	-0.009	-0.034	-0.042	-0.038	-0.022	0.016
42	40.98	40	0.4273	0.021	0.06	0.031	0.008	0.027	0.022
48	43.4	46	0.5818	-0.001	0.002	-0.007	0.035	-0.006	-0.016

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.911588 Pr < W <.0001
Kolmogorov-Smirnov	D	0.087132 Pr > D <.0100
Cramer-von Mises	W-Sq	4.395787 Pr > W-Sq <.0050
Anderson-Darling	A-Sq	25.6195 Pr > A-Sq <.0050

- Jam 04:00

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.82242	0.02027	40.57	<.0001	1	y	0
AR1,2	0.09622	0.02026	4.75	<.0001	3	y	0
NUM1	0.39047	0.04584	8.52	<.0001	0	t	0
NUM2	2058.6	37.86458	54.37	<.0001	0	D1	0
NUM3	2165.4	37.7995	57.29	<.0001	0	D2	0
NUM4	2170.6	37.86361	57.33	<.0001	0	D3	0
NUM5	2178.9	37.9006	57.49	<.0001	0	D4	0
NUM6	2169.1	37.92379	57.2	<.0001	0	D5	0
NUM7	2153.5	37.90891	56.81	<.0001	0	D6	0
NUM8	2086.4	37.89953	55.05	<.0001	0	D7	0
NUM9	-48.6123	26.39228	-1.84	0.0657	0	DV1	0
NUM10	27.17805	23.45189	1.16	0.2467	0	DV2	0
NUM11	57.18135	29.99211	1.91	0.0568	0	DV3	0
NUM12	2.20573	25.97195	0.08	0.9323	0	DV4	0

NUM13	45.35071	26.20615	1.73	0.0838	0	DV5	0
NUM14	77.4155	36.74392	2.11	0.0353	0	DV6	0
NUM15	27.84113	26.1872	1.06	0.2879	0	DV7	0
NUM16	14.59679	30.07151	0.49	0.6275	0	DV8	0
NUM17	-9.86138	26.09038	-0.38	0.7055	0	DV9	0
NUM18	63.71858	30.06852	2.12	0.0343	0	DV10	0
NUM19	40.89672	33.09738	1.24	0.2168	0	DV11	0
NUM20	17.29181	41.64886	0.42	0.6781	0	DV12	0
NUM21	-111.153	45.26879	-2.46	0.0142	0	DV13	0
NUM22	-326.86	47.11827	-6.94	<.0001	0	DV14	0
NUM23	-637.205	47.08194	-13.53	<.0001	0	DV15	0
NUM24	-524.428	45.19462	-11.6	<.0001	0	DV16	0
NUM25	-405.925	41.5747	-9.76	<.0001	0	DV17	0
NUM26	-270.648	33.02437	-8.2	<.0001	0	DV18	0
NUM27	18.07629	30.04201	0.6	0.5475	0	DV19	0
NUM28	14.84323	30.00245	0.49	0.6209	0	DV20	0
NUM29	-16.5935	30.21365	-0.55	0.5829	0	DV21	0

## Autocorrelation Check of Residuals

To	Chi-	DF	Pr >	-----Autocorrelations-----					
Lag	Square		ChiSq						
6	3.6	4	0.4622	0.022	-0.032	-0.027	0.009	0.01	-0.007
12	8.15	10	0.6139	0.024	0.005	-0.019	-0.018	-0.022	0.037
18	13.87	16	0.6082	0.016	0.027	-0.016	0.014	-0.03	0.04
24	21.77	22	0.4738	0.003	0.063	-0.026	0.025	0.008	0.002
30	29.19	28	0.4029	-0.024	0.005	-0.026	-0.009	-0.06	-0.001
36	40.12	34	0.2171	-0.01	-0.059	-0.037	-0.034	-0.021	0.026
42	48.83	40	0.1595	0.02	0.056	0.031	0	0.025	0.025
48	51.58	46	0.2647	-0.001	0.005	-0.018	0.03	-0.004	-0.023

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.909552 Pr < W <.0001
Kolmogorov-Smirnov	D	0.086355 Pr > D <0.0100
Cramer-von Mises	W-Sq	4.511933 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	26.16487 Pr > A-Sq <0.0050

- Jam 04:30

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.81189	0.02026	40.07	<.0001	1	y	0
AR1,2	0.08941	0.02027	4.41	<.0001	3	y	0
NUM1	0.38776	0.0368	10.54	<.0001	0	t	0
NUM2	2165.9	30.72093	70.5	<.0001	0	D1	0
NUM3	2272	30.66834	74.08	<.0001	0	D2	0

NUM4	2279.7	30.72007	74.21	<.0001	0	D3	0
NUM5	2283.5	30.75224	74.25	<.0001	0	D4	0
NUM6	2269.8	30.77207	73.76	<.0001	0	D5	0
NUM7	2254.3	30.75816	73.29	<.0001	0	D6	0
NUM8	2165.1	30.74941	70.41	<.0001	0	D7	0
NUM9	-91.295	24.97421	-3.66	0.0003	0	DV1	0
NUM10	-12.2562	22.28474	-0.55	0.5824	0	DV2	0
NUM11	25.63354	28.49767	0.9	0.3685	0	DV3	0
NUM12	-19.2915	24.68642	-0.78	0.4347	0	DV4	0
NUM13	31.28871	24.91286	1.26	0.2093	0	DV5	0
NUM14	61.0226	34.91309	1.75	0.0807	0	DV6	0
NUM15	18.40617	24.88998	0.74	0.4597	0	DV7	0
NUM16	3.68716	28.57206	0.13	0.8973	0	DV8	0
NUM17	-16.4898	24.7924	-0.67	0.5061	0	DV9	0
NUM18	26.88581	28.56452	0.94	0.3467	0	DV10	0
NUM19	41.40337	31.40495	1.32	0.1876	0	DV11	0
NUM20	-8.29084	39.49794	-0.21	0.8338	0	DV12	0
NUM21	-141.568	42.96221	-3.3	0.001	0	DV13	0
NUM22	-223.943	44.69765	-5.01	<.0001	0	DV14	0
NUM23	-614.484	44.65639	-13.76	<.0001	0	DV15	0
NUM24	-508.5	42.8737	-11.86	<.0001	0	DV16	0
NUM25	-398.099	39.41763	-10.1	<.0001	0	DV17	0
NUM26	-265.042	31.33071	-8.46	<.0001	0	DV18	0
NUM27	-6.25851	28.52092	-0.22	0.8263	0	DV19	0
NUM28	-30.2123	28.50588	-1.06	0.2894	0	DV20	0
NUM29	-30.081	28.70716	-1.05	0.2949	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.91	4	0.1409	0.037	-0.05	-0.024	-0.004	-0.012	-0.01
12	13.77	10	0.1838	0.051	0.005	-0.01	-0.029	-0.021	0.025
18	18.22	16	0.3114	0.03	0.03	-0.007	0.004	-0.021	0.026
24	22.8	22	0.413	0.016	0.04	-0.012	0.03	0.015	-0.002
30	33.32	28	0.224	-0.043	0.028	-0.014	-0.001	-0.064	0.012
36	42.41	34	0.1526	0.019	-0.059	-0.012	-0.044	0.005	-0.005
42	50.04	40	0.1327	0.035	0.048	0.017	0.022	0.015	0.023
48	53.88	46	0.1984	-0.027	0.005	0.011	0.038	-0.004	-0.015

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.942728 Pr < W <.00001
Kolmogorov-Smirnov	D	0.083863 Pr > D <0.0100
Cramer-von Mises	W-Sq	3.47801 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	20.60848 Pr > A-Sq <0.0050

• Jam 05:00

The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
AR1,1	0.72905	0.02096	34.78	<.0001	1	y	0		
AR1,2	0.06994	0.02203	3.17	0.0015	3	y	0		
AR1,3	0.07776	0.01854	4.19	<.0001	7	y	0		
NUM1	0.38401	0.0289	13.29	<.0001	0	t	0		
NUM2	2306.2	24.44	94.36	<.0001	0	D1	0		
NUM3	2409.6	24.39877	98.76	<.0001	0	D2	0		
NUM4	2419.6	24.44445	98.98	<.0001	0	D3	0		
NUM5	2413.1	24.47585	98.59	<.0001	0	D4	0		
NUM6	2402.2	24.49267	98.08	<.0001	0	D5	0		
NUM7	2383.7	24.47843	97.38	<.0001	0	D6	0		
NUM8	2253.5	24.46708	92.1	<.0001	0	D7	0		
NUM9	-139.181	24.9438	-5.58	<.0001	0	DV1	0		
NUM10	-56.3839	22.32629	-2.53	0.0117	0	DV2	0		
NUM11	-39.1393	28.57064	-1.37	0.1709	0	DV3	0		
NUM12	-66.3516	24.74927	-2.68	0.0074	0	DV4	0		
NUM13	-22.1081	24.93483	-0.89	0.3754	0	DV5	0		
NUM14	-9.42909	35.02149	-0.27	0.7878	0	DV6	0		
NUM15	-9.24446	24.94237	-0.37	0.711	0	DV7	0		
NUM16	-42.5213	28.63668	-1.48	0.1378	0	DV8	0		
NUM17	-52.1146	24.86295	-2.1	0.0363	0	DV9	0		
NUM18	-32.6704	28.64386	-1.14	0.2542	0	DV10	0		
NUM19	5.19537	30.24161	0.17	0.8636	0	DV11	0		
NUM20	-95.3677	36.73482	-2.6	0.0095	0	DV12	0		
NUM21	-269.576	39.3308	-6.85	<.0001	0	DV13	0		
NUM22	-120.722	40.55669	-2.98	0.003	0	DV14	0		
NUM23	-582.142	40.49825	-14.37	<.0001	0	DV15	0		
NUM24	-494.834	39.23207	-12.61	<.0001	0	DV16	0		
NUM25	-396.049	36.67522	-10.8	<.0001	0	DV17	0		
NUM26	-268.183	30.20757	-8.88	<.0001	0	DV18	0		
NUM27	-129.042	28.57717	-4.52	<.0001	0	DV19	0		
NUM28	-97.3312	28.57973	-3.41	0.0007	0	DV20	0		
NUM29	-31.8768	28.80099	-1.11	0.2686	0	DV21	0		
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.28	3	0.0633	0.045	-0.054	0.001	-0.005	-0.003	0.001
12	15.93	9	0.0683	0.029	-0.031	-0.037	-0.032	-0.037	-0.015
18	22.36	15	0.0987	0.013	0.046	0.002	0.021	-0.032	0.023
24	25.58	21	0.2227	0.01	0.024	0.015	0.035	0.004	-0.002
30	30.84	27	0.2777	-0.026	0.032	0.013	0.011	-0.035	0.018
36	35.2	33	0.3644	0.044	-0.021	0.018	-0.014	0.008	0.003
42	38.89	39	0.4747	0.014	0.026	0.018	0.025	0.023	0.008

48    42.04    45    0.598    -0.016    0.01    0.016    0.029    0.025    -0.004

Test	Tests for Normality			
	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.944964	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.090533	Pr > D	<0.0100
Cramer-von Mises	W-Sq	3.796941	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	22.03779	Pr > A-Sq	<0.0050

## • Jam 05:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.72121	0.02113	34.14	<.0001	1	y	0
AR1,2	0.05244	0.02194	2.39	0.017	3	y	0
AR1,3	0.11538	0.01867	6.18	<.0001	7	y	0
NUM1	0.38324	0.03218	11.91	<.0001	0	t	0
NUM2	2410.2	27.16239	88.73	<.0001	0	D1	0
NUM3	2496.1	27.11697	92.05	<.0001	0	D2	0
NUM4	2511	27.17233	92.41	<.0001	0	D3	0
NUM5	2495.8	27.20969	91.73	<.0001	0	D4	0
NUM6	2489.4	27.22859	91.43	<.0001	0	D5	0
NUM7	2462.9	27.21194	90.51	<.0001	0	D6	0
NUM8	2297.4	27.19683	84.47	<.0001	0	D7	0
NUM9	-188.675	25.54621	-7.39	<.0001	0	DV1	0
NUM10	-97.5562	22.8058	-4.28	<.0001	0	DV2	0
NUM11	-91.2162	29.19408	-3.12	0.0018	0	DV3	0
NUM12	-112.611	25.28734	-4.45	<.0001	0	DV4	0
NUM13	-88.5637	25.47613	-3.48	0.0005	0	DV5	0
NUM14	-83.2792	35.7677	-2.33	0.02	0	DV6	0
NUM15	-43.4859	25.49203	-1.71	0.0883	0	DV7	0
NUM16	-71.0672	29.25953	-2.43	0.0153	0	DV8	0
NUM17	-95.3102	25.41396	-3.75	0.0002	0	DV9	0
NUM18	-91.7268	29.27216	-3.13	0.0018	0	DV10	0
NUM19	-43.0329	30.61918	-1.41	0.1601	0	DV11	0
NUM20	-191.871	36.88946	-5.2	<.0001	0	DV12	0
NUM21	-394.463	39.30042	-10.04	<.0001	0	DV13	0
NUM22	-49.0793	40.41035	-1.21	0.2247	0	DV14	0
NUM23	-510.497	40.39203	-12.64	<.0001	0	DV15	0
NUM24	-445.298	39.29125	-11.33	<.0001	0	DV16	0
NUM25	-365.892	36.8651	-9.93	<.0001	0	DV17	0
NUM26	-251.223	30.61166	-8.21	<.0001	0	DV18	0
NUM27	-275.643	29.20695	-9.44	<.0001	0	DV19	0
NUM28	-156.276	29.20372	-5.35	<.0001	0	DV20	0
NUM29	-52.2279	29.46253	-1.77	0.0765	0	DV21	0

Autocorrelation Check of Residuals									
To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	3	3	0.3913	0.027	-0.023	-0.002	-0.006	0.026	-0.006
12	13.83	9	0.1286	0.046	-0.047	-0.011	-0.046	-0.028	-0.008
18	24	15	0.0651	-0.014	0.056	-0.008	0.049	-0.032	0.008
24	29.38	21	0.1053	0.011	0.011	0.012	0.038	0.006	-0.042
30	31.25	27	0.2611	0	0.011	0.006	0.014	-0.026	0.015
36	34.42	33	0.3995	0.038	0.014	0.016	-0.003	-0.014	-0.009
42	37.4	39	0.5429	-0.021	0.002	-0.023	0	0.004	-0.031
48	43.63	45	0.5302	-0.05	-0.005	0.016	-0.002	0.035	0.011

Tests for Normality				
Test	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.942957	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.081081	Pr > D	<0.0100
Cramer-von Mises	W-Sq	3.809718	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	22.41948	Pr > A-Sq	<0.0050

- Jam 06:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.6932	0.02648	26.18	<.0001	1	y	0
AR1,2	0.09714	0.02691	3.61	0.0003	2	y	0
AR1,3	0.11536	0.01805	6.39	<.0001	7	y	0
NUM1	0.38479	0.03774	10.19	<.0001	0	t	0
NUM2	2332.1	31.5582	73.9	<.0001	0	D1	0
NUM3	2399.3	31.50545	76.15	<.0001	0	D2	0
NUM4	2411	31.5637	76.38	<.0001	0	D3	0
NUM5	2396.9	31.61033	75.83	<.0001	0	D4	0
NUM6	2396.7	31.63253	75.77	<.0001	0	D5	0
NUM7	2359.4	31.61272	74.63	<.0001	0	D6	0
NUM8	2199.5	31.59278	69.62	<.0001	0	D7	0
NUM9	-238.965	26.44758	-9.04	<.0001	0	DV1	0
NUM10	-142.816	23.52721	-6.07	<.0001	0	DV2	0
NUM11	-153.804	30.1479	-5.1	<.0001	0	DV3	0
NUM12	-139.086	26.10735	-5.33	<.0001	0	DV4	0
NUM13	-127.071	26.2939	-4.83	<.0001	0	DV5	0
NUM14	-180.559	36.92841	-4.89	<.0001	0	DV6	0
NUM15	-63.1477	26.41857	-2.39	0.017	0	DV7	0
NUM16	-116.56	30.20273	-3.86	0.0001	0	DV8	0
NUM17	-128.702	26.34454	-4.89	<.0001	0	DV9	0
NUM18	-162.66	30.20287	-5.39	<.0001	0	DV10	0
NUM19	-73.3876	31.22644	-2.35	0.0189	0	DV11	0
NUM20	-268.547	37.05146	-7.25	<.0001	0	DV12	0

NUM21	-537.645	40.1359	-13.4	<.0001	0	DV13	0
NUM22	-221.689	41.44003	-5.35	<.0001	0	DV14	0
NUM23	-410.233	41.44041	-9.9	<.0001	0	DV15	0
NUM24	-360.232	40.14028	-8.97	<.0001	0	DV16	0
NUM25	-291.759	37.05052	-7.87	<.0001	0	DV17	0
NUM26	-203.901	31.2233	-6.53	<.0001	0	DV18	0
NUM27	-578.643	30.199	-19.16	<.0001	0	DV19	0
NUM28	-214.098	30.14791	-7.1	<.0001	0	DV20	0
NUM29	-62.4031	30.37739	-2.05	0.0401	0	DV21	0

## Autocorrelation Check of Residuals

To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	5.58	3	0.1338	-0.002	-0.024	-0.017	0.015	0.03	0.042
12	11.05	9	0.2723	-0.002	-0.007	0.04	-0.044	0	-0.012
18	14.74	15	0.4702	-0.015	0.027	0.026	0.027	-0.001	-0.013
24	18.82	21	0.5969	0.013	0.026	-0.004	0.036	0.017	-0.016
30	20.22	27	0.8215	-0.002	-0.014	0.009	-0.009	-0.024	-0.001
36	26.25	33	0.7917	0.029	0.012	-0.016	0.024	-0.045	-0.013
42	34.4	39	0.6795	-0.043	-0.025	-0.014	-0.029	-0.005	-0.043
48	40.18	45	0.676	-0.047	0.009	0.007	-0.014	0.034	0.011

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.92642 Pr < W <.0001
Kolmogorov-Smirnov	D	0.082953 Pr > D <.0100
Cramer-von Mises	W-Sq	3.556716 Pr > W-Sq <.0050
Anderson-Darling	A-Sq	20.90556 Pr > A-Sq <.0050

- Jam 06:30

The ARIMA Procedure  
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.58302	0.02654	21.97	<.0001	1	y	0
AR1,2	0.13816	0.02753	5.02	<.0001	2	y	0
AR1,3	0.08242	0.02412	3.42	0.0007	5	y	0
AR1,4	0.08625	0.02291	3.76	0.0002	7	y	0
NUM1	0.37972	0.03257	11.66	<.0001	0	t	0
NUM2	2202.9	27.36511	80.5	<.0001	0	D1	0
NUM3	2273.6	27.31992	83.22	<.0001	0	D2	0
NUM4	2281.3	27.36051	83.38	<.0001	0	D3	0
NUM5	2271.1	27.39762	82.9	<.0001	0	D4	0
NUM6	2270.2	27.41742	82.8	<.0001	0	D5	0
NUM7	2219	27.39838	80.99	<.0001	0	D6	0
NUM8	2104.3	27.38613	76.84	<.0001	0	D7	0
NUM9	-263.883	27.51043	-9.59	<.0001	0	DV1	0



NUM10	-140.024	24.41945	-5.73	<.0001	0	DV2	0
NUM11	-145.464	31.34179	-4.64	<.0001	0	DV3	0
NUM12	-136.854	27.15975	-5.04	<.0001	0	DV4	0
NUM13	-121.794	27.34322	-4.45	<.0001	0	DV5	0
NUM14	-216.521	38.39331	-5.64	<.0001	0	DV6	0
NUM15	-61.9805	27.47974	-2.26	0.0243	0	DV7	0
NUM16	-119.186	31.3889	-3.8	0.0002	0	DV8	0
NUM17	-108.87	27.40061	-3.97	<.0001	0	DV9	0
NUM18	-225.657	31.38379	-7.19	<.0001	0	DV10	0
NUM19	-97.1503	31.04347	-3.13	0.0018	0	DV11	0
NUM20	-275.679	35.00799	-7.87	<.0001	0	DV12	0
NUM21	-591.551	37.04447	-15.97	<.0001	0	DV13	0
NUM22	-572.194	37.5971	-15.22	<.0001	0	DV14	0
NUM23	-387.977	37.60387	-10.32	<.0001	0	DV15	0
NUM24	-357.818	37.05217	-9.66	<.0001	0	DV16	0
NUM25	-295.585	35.00283	-8.44	<.0001	0	DV17	0
NUM26	-209.28	31.03941	-6.74	<.0001	0	DV18	0
NUM27	-693.163	31.42121	-22.06	<.0001	0	DV19	0
NUM28	-207.335	31.36533	-6.61	<.0001	0	DV20	0
NUM29	-150.385	31.51191	-4.77	<.0001	0	DV21	0
AR1,1	0.58302	0.02654	21.97	<.0001	1	y	0
AR1,2	0.13816	0.02753	5.02	<.0001	2	y	0

## Autocorrelation Check of Residuals

To	Chi-	DF	Pr >	-----Autocorrelations-----					
Lag	Square		ChiSq						
6	5.7	2	0.0578	-0.012	-0.028	0.015	0.024	-0.026	0.039
12	11.09	8	0.1966	-0.029	0.011	0.029	0.005	-0.034	-0.027
18	17.87	14	0.2129	0	0.021	0	0.048	0.043	-0.006
24	22.5	20	0.3141	0.024	0.023	-0.02	0.034	0.013	-0.017
30	25.51	26	0.4905	-0.01	-0.015	0.029	0.001	-0.029	-0.005
36	28.31	32	0.6541	0.012	-0.01	-0.008	0.014	-0.032	-0.018
42	35.87	38	0.5685	-0.044	-0.027	0.017	-0.045	-0.005	-0.002
48	43.88	44	0.4768	-0.034	-0.013	0.026	-0.035	0.045	0.002

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.889389 Pr < W
Kolmogorov-Smirnov	D	0.9586 Pr > D
Cramer-von Mises	W-Sq	4.104947 Pr > W-Sq
Anderson-Darling	A-Sq	23.67882 Pr > A-Sq

- Jam 07:00

The ARIMA Procedure  
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
-----------	----------	-------------------	---------	-------------------	-----	----------	-------

AR1,1	0.53446	0.02641	20.24	<.0001	1	y	0
AR1,2	0.13613	0.02701	5.04	<.0001	2	y	0
AR1,3	0.08481	0.02404	3.53	0.0004	5	y	0
AR1,4	0.1116	0.02338	4.77	<.0001	7	y	0
NUM1	0.38541	0.02627	14.67	<.0001	0	t	0
NUM2	2137	22.26568	95.98	<.0001	0	D1	0
NUM3	2206	22.22898	99.24	<.0001	0	D2	0
NUM4	2202.2	22.261	98.93	<.0001	0	D3	0
NUM5	2197.9	22.29411	98.59	<.0001	0	D4	0
NUM6	2196.3	22.3108	98.44	<.0001	0	D5	0
NUM7	2127.9	22.29367	95.45	<.0001	0	D6	0
NUM8	2033.3	22.28275	91.25	<.0001	0	D7	0
NUM9	-305.659	26.61881	-11.48	<.0001	0	DV1	0
NUM10	-143.462	23.75179	-6.04	<.0001	0	DV2	0
NUM11	-112.656	30.50314	-3.69	0.0002	0	DV3	0
NUM12	-129.291	26.41489	-4.89	<.0001	0	DV4	0
NUM13	-108.965	26.59883	-4.1	<.0001	0	DV5	0
NUM14	-228.913	37.34829	-6.13	<.0001	0	DV6	0
NUM15	-67.9859	26.72324	-2.54	0.0111	0	DV7	0
NUM16	-94.9348	30.53972	-3.11	0.0019	0	DV8	0
NUM17	-93.4697	26.65515	-3.51	0.0005	0	DV9	0
NUM18	-297.519	30.54176	-9.74	<.0001	0	DV10	0
NUM19	-97.7853	29.7225	-3.29	0.001	0	DV11	0
NUM20	-285.153	32.87553	-8.67	<.0001	0	DV12	0
NUM21	-619.257	34.45173	-17.97	<.0001	0	DV13	0
NUM22	-729.908	34.8019	-20.97	<.0001	0	DV14	0
NUM23	-443.567	34.81049	-12.74	<.0001	0	DV15	0
NUM24	-403.455	34.45782	-11.71	<.0001	0	DV16	0
NUM25	-331.606	32.8672	-10.09	<.0001	0	DV17	0
NUM26	-225.503	29.71609	-7.59	<.0001	0	DV18	0
NUM27	-688.015	30.58095	-22.5	<.0001	0	DV19	0
NUM28	-201.727	30.51039	-6.61	<.0001	0	DV20	0
NUM29	-174.048	30.73073	-5.66	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.72	2	0.0573	-0.01	-0.019	-0.01	0.028	-0.029	0.041
12	13.87	8	0.0851	-0.031	-0.013	0.025	0.022	-0.028	-0.05
18	19.78	14	0.1373	0	0.021	0.036	0.038	0.028	0.006
24	24.06	20	0.2399	0.044	-0.019	0.014	0.009	0.011	0.012
30	26.64	26	0.4282	-0.027	0	0.025	0.016	0.01	-0.005
36	30.33	32	0.5514	-0.006	0.018	-0.04	0.006	-0.009	-0.02
42	35.77	38	0.5729	-0.043	-0.023	0.02	-0.026	0.003	-0.014
48	39.51	44	0.6644	0.01	-0.006	0.016	-0.013	0.043	-0.006

Test	Tests for Normality			
	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.886491	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.087087	Pr > D	<0.0100
Cramer-von Mises	W-Sq	3.232772	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	19.57454	Pr > A-Sq	<0.0050

- Jam 07:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.47764	0.02632	18.15	<.0001	1	y	0
AR1,2	0.11468	0.02744	4.18	<.0001	2	y	0
AR1,3	0.06965	0.02503	2.78	0.0055	4	y	0
AR1,4	0.07689	0.0274	2.81	0.0051	6	y	0
AR1,5	0.12161	0.02632	4.62	<.0001	7	y	0
NUM1	0.41301	0.02754	15	<.0001	0	t	0
NUM2	2198.1	23.40387	93.92	<.0001	0	D1	0
NUM3	2261.7	23.36567	96.8	<.0001	0	D2	0
NUM4	2250.6	23.39803	96.19	<.0001	0	D3	0
NUM5	2252	23.4334	96.1	<.0001	0	D4	0
NUM6	2243.9	23.44718	95.7	<.0001	0	D5	0
NUM7	2146.1	23.43242	91.59	<.0001	0	D6	0
NUM8	2002.9	23.41921	85.53	<.0001	0	D7	0
NUM9	-392.61	30.14967	-13.02	<.0001	0	DV1	0
NUM10	-226.464	26.83574	-8.44	<.0001	0	DV2	0
NUM11	-194.047	34.45926	-5.63	<.0001	0	DV3	0
NUM12	-195.338	29.83106	-6.55	<.0001	0	DV4	0
NUM13	-169.159	30.02754	-5.63	<.0001	0	DV5	0
NUM14	-333.949	42.17942	-7.92	<.0001	0	DV6	0
NUM15	-129.866	30.13293	-4.31	<.0001	0	DV7	0
NUM16	-150.734	34.5218	-4.37	<.0001	0	DV8	0
NUM17	-146.598	30.05508	-4.88	<.0001	0	DV9	0
NUM18	-412.803	34.49822	-11.97	<.0001	0	DV10	0
NUM19	-113.349	32.79158	-3.46	0.0006	0	DV11	0
NUM20	-328.164	35.34991	-9.28	<.0001	0	DV12	0
NUM21	-686.214	36.35002	-18.88	<.0001	0	DV13	0
NUM22	-831.043	36.57289	-22.72	<.0001	0	DV14	0
NUM23	-570.759	36.57165	-15.61	<.0001	0	DV15	0
NUM24	-509.44	36.36368	-14.01	<.0001	0	DV16	0
NUM25	-410.716	35.34649	-11.62	<.0001	0	DV17	0
NUM26	-271.122	32.77114	-8.27	<.0001	0	DV18	0
NUM27	-724.051	34.56821	-20.95	<.0001	0	DV19	0
NUM28	-278.209	34.48061	-8.07	<.0001	0	DV20	0
NUM29	-270.025	34.7236	-7.78	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	0.58	1	0.4463	-0.002	-0.011	0.005	-0.004	0.012	-0.008
12	12.57	7	0.0832	-0.02	-0.037	0.022	0.007	-0.033	-0.069
18	22.67	13	0.0458	0.011	0.037	0.029	0.021	0.063	-0.013
24	25.76	19	0.1371	0.036	-0.014	0.017	0.006	0.012	0.01
30	30.52	25	0.2052	-0.029	0.028	0.025	0.021	0.015	0.018
36	35.6	31	0.2606	-0.016	0.004	-0.033	0.035	-0.027	0.007
42	44.65	37	0.1812	-0.045	-0.047	0.03	-0.025	-0.013	0.008
48	48.76	43	0.2527	0.022	0.019	0	-0.008	0.04	-0.013

Tests for Normality			
Test	---Statistic---	-----p Value-----	
Shapiro-Wilk	W	0.853644	Pr < W < 0.0001
Kolmogorov-Smirnov	D	0.102222	Pr > D < 0.0100
Cramer-von Mises	W-Sq	5.280723	Pr > W-Sq < 0.0050
Anderson-Darling	A-Sq	31.20911	Pr > A-Sq < 0.0050

- Jam 08:00

#### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.4639	0.02614	17.75	<.0001	1	y	0
AR1,2	0.10592	0.0271	3.91	<.0001	2	y	0
AR1,3	0.06836	0.02404	2.84	0.0045	4	y	0
AR1,4	0.15776	0.02372	6.65	<.0001	7	y	0
AR1,5	0.07306	0.02225	3.28	0.001	14	y	0
NUM1	0.43463	0.03136	13.86	<.0001	0	t	0
NUM2	2277.3	26.60519	85.59	<.0001	0	D1	0
NUM3	2332.6	26.56135	87.82	<.0001	0	D2	0
NUM4	2318.8	26.60641	87.15	<.0001	0	D3	0
NUM5	2320.6	26.64894	87.08	<.0001	0	D4	0
NUM6	2308.4	26.66148	86.58	<.0001	0	D5	0
NUM7	2191.5	26.64844	82.24	<.0001	0	D6	0
NUM8	1999.1	26.6334	75.06	<.0001	0	D7	0
NUM9	-468.262	33.13394	-14.13	<.0001	0	DV1	0
NUM10	-291.427	29.4797	-9.89	<.0001	0	DV2	0
NUM11	-263.641	37.86258	-6.96	<.0001	0	DV3	0
NUM12	-257.802	32.78329	-7.86	<.0001	0	DV4	0
NUM13	-246.138	32.96882	-7.47	<.0001	0	DV5	0
NUM14	-395.562	46.38753	-8.53	<.0001	0	DV6	0
NUM15	-179.179	33.10789	-5.41	<.0001	0	DV7	0
NUM16	-168.626	37.92219	-4.45	<.0001	0	DV8	0

NUM17	-194.458	33.04057	-5.89	<.0001	0	DV9	0
NUM18	-506.409	37.91185	-13.36	<.0001	0	DV10	0
NUM19	-132.957	36.04825	-3.69	0.0002	0	DV11	0
NUM20	-398.544	38.95572	-10.23	<.0001	0	DV12	0
NUM21	-777.078	40.17281	-19.34	<.0001	0	DV13	0
NUM22	-942.681	40.39987	-23.33	<.0001	0	DV14	0
NUM23	-689.536	40.38647	-17.07	<.0001	0	DV15	0
NUM24	-582.388	40.15207	-14.5	<.0001	0	DV16	0
NUM25	-466.166	38.94339	-11.97	<.0001	0	DV17	0
NUM26	-305.411	36.04188	-8.47	<.0001	0	DV18	0
NUM27	-785.858	37.96918	-20.7	<.0001	0	DV19	0
NUM28	-370.975	37.88605	-9.79	<.0001	0	DV20	0
NUM29	-353.376	38.25101	-9.24	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	3.18	1	0.0744	-0.005	-0.014	-0.003	-0.01	0.006	0.043
12	11.41	7	0.1218	0	-0.031	0.035	0.014	-0.006	-0.057
18	20.21	13	0.0901	0.001	-0.028	0.027	0.022	0.057	-0.025
24	23.59	19	0.2123	0.022	-0.014	0.013	0.021	-0.019	0.025
30	27.52	25	0.3305	-0.001	0.015	0.027	0.041	0.004	0
36	32.49	31	0.3934	-0.011	-0.013	-0.033	0.031	-0.027	0.017
42	41.36	37	0.2859	-0.05	-0.037	0.038	-0.022	-0.012	0.005
48	42.56	43	0.4903	0.012	0.007	-0.01	-0.01	0.005	-0.019

Tests for Normality			
Test	---Statistic---	-----p Value-----	
Shapiro-Wilk	W	0.819645	Pr < W <.0001
Kolmogorov-Smirnov	D	0.122897	Pr > D <0.0100
Cramer-von Mises	W-Sq	7.230155	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	42.11312	Pr > A-Sq <0.0050

- Jam 08:30

#### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.45397	0.0261	17.39	<.0001	1	y	0
AR1,2	0.10181	0.02693	3.78	0.0002	2	y	0
AR1,3	0.08316	0.02399	3.47	0.0005	4	y	0
AR1,4	0.19584	0.02281	8.59	<.0001	7	y	0
NUM1	0.4478	0.02875	15.58	<.0001	0	t	0
NUM2	2369.8	24.72714	95.84	<.0001	0	D1	0
NUM3	2420.9	24.6876	98.06	<.0001	0	D2	0
NUM4	2405.9	24.72635	97.3	<.0001	0	D3	0

NUM5	2408.8	24.76674	97.26	<.0001	0	D4	0
NUM6	2391.3	24.77776	96.51	<.0001	0	D5	0
NUM7	2267.7	24.76136	91.58	<.0001	0	D6	0
NUM8	2016.8	24.74774	81.5	<.0001	0	D7	0
NUM9	-550.571	36.84377	-14.94	<.0001	0	DV1	0
NUM10	-353.747	32.68694	-10.82	<.0001	0	DV2	0
NUM11	-316.32	41.97681	-7.54	<.0001	0	DV3	0
NUM12	-325.599	36.35085	-8.96	<.0001	0	DV4	0
NUM13	-298.047	36.55478	-8.15	<.0001	0	DV5	0
NUM14	-484.31	51.40328	-9.42	<.0001	0	DV6	0
NUM15	-215.982	36.6971	-5.89	<.0001	0	DV7	0
NUM16	-202.77	42.03767	-4.82	<.0001	0	DV8	0
NUM17	-233.3	36.62077	-6.37	<.0001	0	DV9	0
NUM18	-581.234	42.04674	-13.82	<.0001	0	DV10	0
NUM19	-134.427	39.91445	-3.37	0.0008	0	DV11	0
NUM20	-408.358	42.65338	-9.57	<.0001	0	DV12	0
NUM21	-806.258	43.77087	-18.42	<.0001	0	DV13	0
NUM22	-1041.5	43.95467	-23.7	<.0001	0	DV14	0
NUM23	-793.428	43.95723	-18.05	<.0001	0	DV15	0
NUM24	-662.754	43.79962	-15.13	<.0001	0	DV16	0
NUM25	-533.077	42.64689	-12.5	<.0001	0	DV17	0
NUM26	-342.701	39.89435	-8.59	<.0001	0	DV18	0
NUM27	-858.105	42.09734	-20.38	<.0001	0	DV19	0
NUM28	-437.858	41.98311	-10.43	<.0001	0	DV20	0
NUM29	-390.892	42.55292	-9.19	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.95	2	0.0843	-0.009	-0.029	0.021	-0.028	0.024	0.025
12	14.48	8	0.0701	-0.032	-0.037	0.019	0.007	-0.005	-0.06
18	23.12	14	0.0584	-0.006	0.039	0.046	0.025	0.039	-0.005
24	31	20	0.0551	0.036	-0.017	0.009	0.047	-0.009	0.037
30	35.74	26	0.0966	0.014	0.017	0.019	0.044	0.017	-0.009
36	42.89	32	0.0946	0.005	-0.02	-0.041	0.049	-0.014	-0.01
42	50.36	38	0.0865	-0.022	-0.048	0.046	-0.01	-0.001	0.004
48	52.55	44	0.1767	0.008	0.036	0.001	-0.006	0.006	0.005

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.793147 Pr < W
Kolmogorov-Smirnov	D	0.129567 Pr > D
Cramer-von Mises	W-Sq	8.583521 Pr > W-Sq
Anderson-Darling	A-Sq	50.62553 Pr > A-Sq

• Jam 09:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.43054	0.0261	16.5	<.0001	1	y	0
AR1,2	0.11514	0.02688	4.28	<.0001	2	y	0
AR1,3	0.08622	0.02425	3.55	0.0004	4	y	0
AR1,4	0.19283	0.02308	8.36	<.0001	7	y	0
NUM1	0.45503	0.02887	15.76	<.0001	0	t	0
NUM2	2415.1	24.91859	96.92	<.0001	0	D1	0
NUM3	2461	24.87939	98.92	<.0001	0	D2	0
NUM4	2444	24.91578	98.09	<.0001	0	D3	0
NUM5	2445.8	24.95752	98	<.0001	0	D4	0
NUM6	2431.9	24.96822	97.4	<.0001	0	D5	0
NUM7	2306.7	24.95043	92.45	<.0001	0	D6	0
NUM8	2030.4	24.93671	81.42	<.0001	0	D7	0
NUM9	-594.166	39.33504	-15.11	<.0001	0	DV1	0
NUM10	-387.022	34.86317	-11.1	<.0001	0	DV2	0
NUM11	-347.603	44.79418	-7.76	<.0001	0	DV3	0
NUM12	-354.894	38.79039	-9.15	<.0001	0	DV4	0
NUM13	-318.572	39.01367	-8.17	<.0001	0	DV5	0
NUM14	-482.146	54.8617	-8.79	<.0001	0	DV6	0
NUM15	-232.463	39.16806	-5.94	<.0001	0	DV7	0
NUM16	-215.845	44.86558	-4.81	<.0001	0	DV8	0
NUM17	-235.27	39.10286	-6.02	<.0001	0	DV9	0
NUM18	-600.578	44.87127	-13.38	<.0001	0	DV10	0
NUM19	-134.871	42.35214	-3.18	0.0015	0	DV11	0
NUM20	-419.118	44.91846	-9.33	<.0001	0	DV12	0
NUM21	-822.614	46.06774	-17.86	<.0001	0	DV13	0
NUM22	-1105.8	46.25561	-23.91	<.0001	0	DV14	0
NUM23	-856.733	46.25521	-18.52	<.0001	0	DV15	0
NUM24	-708.455	46.10083	-15.37	<.0001	0	DV16	0
NUM25	-566.763	44.90795	-12.62	<.0001	0	DV17	0
NUM26	-368.001	42.33106	-8.69	<.0001	0	DV18	0
NUM27	-864.864	44.9259	-19.25	<.0001	0	DV19	0
NUM28	-467.611	44.81023	-10.44	<.0001	0	DV20	0
NUM29	-429.888	45.38018	-9.47	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.31	2	0.0704	-0.012	-0.031	0.022	-0.029	0.023	0.026
12	13.32	8	0.1013	-0.035	-0.033	0.021	0.018	-0.003	-0.048
18	24.12	14	0.0443	-0.021	0.032	0.047	0.03	0.05	-0.012
24	30.13	20	0.0677	0.039	-0.016	0.014	0.038	0.007	0.024
30	35.54	26	0.1004	0.017	0.009	0.025	0.049	0.01	-0.012
36	42.4	32	0.1035	0.008	-0.02	-0.034	0.047	-0.016	-0.021

42	48.47	38	0.119	-0.01	-0.039	0.046	0.006	-0.016	0.002
48	50.96	44	0.2189	0.006	0.038	-0.001	-0.009	-0.004	0.006
6	5.31	2	0.0704	-0.012	-0.031	0.022	-0.029	0.023	0.026
12	13.32	8	0.1013	-0.035	-0.033	0.021	0.018	-0.003	-0.048
18	24.12	14	0.0443	-0.021	0.032	0.047	0.03	0.05	-0.012

Test	Tests for Normality			
	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.77063	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.133962	Pr > D	<0.0100
Cramer-von Mises	W-Sq	10.10619	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	58.57283	Pr > A-Sq	<0.0050

- Jam 09:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.39427	0.02599	15.17	<.0001	1	y	0
AR1,2	0.10965	0.02655	4.13	<.0001	2	y	0
AR1,3	0.0656	0.02479	2.65	0.0082	4	y	0
AR1,4	0.1669	0.02426	6.88	<.0001	7	y	0
AR1,5	0.07562	0.02411	3.14	0.0017	14	y	0
AR1,6	0.12247	0.02636	4.65	<.0001	19	y	0
AR1,7	-0.07963	0.02634	-3.02	0.0025	20	y	0
NUM1	0.46757	0.03477	13.45	<.0001	0	t	0
NUM2	2442.2	29.70046	82.23	<.0001	0	D1	0
NUM3	2480	29.65443	83.63	<.0001	0	D2	0
NUM4	2460	29.69649	82.84	<.0001	0	D3	0
NUM5	2462.1	29.73947	82.79	<.0001	0	D4	0
NUM6	2455.1	29.75336	82.51	<.0001	0	D5	0
NUM7	2327	29.73254	78.26	<.0001	0	D6	0
NUM8	2037.9	29.72464	68.56	<.0001	0	D7	0
NUM9	-596.306	41.62475	-14.33	<.0001	0	DV1	0
NUM10	-391.288	36.83604	-10.62	<.0001	0	DV2	0
NUM11	-376.349	47.42733	-7.94	<.0001	0	DV3	0
NUM12	-366.331	41.04674	-8.92	<.0001	0	DV4	0
NUM13	-339.328	41.26019	-8.22	<.0001	0	DV5	0
NUM14	-486.85	58.08925	-8.38	<.0001	0	DV6	0
NUM15	-228.996	41.4473	-5.52	<.0001	0	DV7	0
NUM16	-187.107	47.51749	-3.94	<.0001	0	DV8	0
NUM17	-240.779	41.35473	-5.82	<.0001	0	DV9	0
NUM18	-617.559	47.46022	-13.01	<.0001	0	DV10	0
NUM19	-158.309	44.34135	-3.57	0.0004	0	DV11	0
NUM20	-470.213	46.94219	-10.02	<.0001	0	DV12	0
NUM21	-845.455	47.99802	-17.61	<.0001	0	DV13	0
NUM22	-1150.6	48.48812	-23.73	<.0001	0	DV14	0



NUM23	-935.451	48.35388	-19.35	<.0001	0	DV15	0
NUM24	-742.848	47.96116	-15.49	<.0001	0	DV16	0
NUM25	-609.931	46.92026	-13	<.0001	0	DV17	0
NUM26	-385.238	44.31186	-8.69	<.0001	0	DV18	0
NUM27	-840.629	47.53521	-17.68	<.0001	0	DV19	0
NUM28	-462.152	47.53519	-9.72	<.0001	0	DV20	0
NUM29	-441.445	47.79127	-9.24	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6		0		-0.01	-0.025	0.02	-0.005	0	0.027
12	7.62	5	0.1787	-0.008	-0.018	0.039	0.022	0.018	-0.023
18	14.27	11	0.2184	0	-0.011	0.034	0.017	0.045	-0.03
24	21.35	17	0.2109	0.021	-0.011	0.01	0.036	-0.004	0.053
30	25.7	23	0.3152	0.011	-0.019	0.024	0.035	-0.001	-0.026
36	31.46	29	0.3442	-0.008	-0.01	-0.04	0.034	-0.03	-0.002
42	41.15	35	0.2191	-0.024	-0.056	0.048	0.008	-0.015	-0.011
48	43.08	41	0.3825	0.01	0.028	-0.005	-0.012	-0.015	0.005

Tests for Normality				
Test	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.750784	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.138285	Pr > D	<0.0100
Cramer-von Mises	W-Sq	11.23933	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	64.98525	Pr > A-Sq	<0.0050

- Jam 10:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.41109	0.02601	15.8	<.0001	1	y	0
AR1,2	0.10799	0.02664	4.05	<.0001	2	y	0
AR1,3	0.08358	0.02466	3.39	0.0007	4	y	0
AR1,4	0.18454	0.02333	7.91	<.0001	7	y	0
AR1,5	0.11349	0.02622	4.33	<.0001	19	y	0
AR1,6	-0.06259	0.02617	-2.39	0.0169	20	y	0
NUM1	0.46845	0.03231	14.5	<.0001	0	t	0
NUM2	2472.9	27.74343	89.14	<.0001	0	D1	0
NUM3	2505.6	27.70079	90.45	<.0001	0	D2	0
NUM4	2484.5	27.73768	89.57	<.0001	0	D3	0
NUM5	2484.6	27.77712	89.45	<.0001	0	D4	0
NUM6	2488.9	27.78802	89.57	<.0001	0	D5	0
NUM7	2355.7	27.76677	84.84	<.0001	0	D6	0
NUM8	2054.2	27.75991	74	<.0001	0	D7	0
NUM9	-603.813	41.74387	-14.46	<.0001	0	DV1	0

NUM10	-392.753	36.88745	-10.65	<.0001	0	DV2	0
NUM11	-382.38	47.46458	-8.06	<.0001	0	DV3	0
NUM12	-383.244	41.07531	-9.33	<.0001	0	DV4	0
NUM13	-337.414	41.32036	-8.17	<.0001	0	DV5	0
NUM14	-488.498	58.11519	-8.41	<.0001	0	DV6	0
NUM15	-224.531	41.4601	-5.42	<.0001	0	DV7	0
NUM16	-220.26	47.49875	-4.64	<.0001	0	DV8	0
NUM17	-231.8	41.37655	-5.6	<.0001	0	DV9	0
NUM18	-629.866	47.512	-13.26	<.0001	0	DV10	0
NUM19	-152.295	44.6536	-3.41	0.0007	0	DV11	0
NUM20	-454.565	47.24592	-9.62	<.0001	0	DV12	0
NUM21	-834.984	48.33504	-17.27	<.0001	0	DV13	0
NUM22	-1144.6	48.7737	-23.47	<.0001	0	DV14	0
NUM23	-955.114	48.68539	-19.62	<.0001	0	DV15	0
NUM24	-768.51	48.35026	-15.89	<.0001	0	DV16	0
NUM25	-628.943	47.23409	-13.32	<.0001	0	DV17	0
NUM26	-397.692	44.63282	-8.91	<.0001	0	DV18	0
NUM27	-831.01	47.57971	-17.47	<.0001	0	DV19	0
NUM28	-478.835	47.54897	-10.07	<.0001	0	DV20	0
NUM29	-458.58	47.96036	-9.56	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.005	-0.027	0.02	-0.006	-0.012	0.013
12	7.16	6	0.3064	-0.025	-0.024	0.026	0.015	0.006	-0.035
18	16.98	12	0.1505	0	0.05	0.035	0.039	0.037	-0.011
24	28.85	18	0.0503	0.011	-0.026	0.017	0.041	-0.019	0.07
30	32.8	24	0.1084	0.011	-0.022	0.01	0.036	0.01	-0.022
36	39.83	30	0.1082	0.011	-0.016	-0.035	0.046	-0.022	-0.022
42	47.79	36	0.0905	-0.011	-0.047	0.051	0.005	-0.018	0.002
48	51.16	42	0.1571	0.014	0.033	-0.003	0.003	-0.03	0.006

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.76371 Pr < W
Kolmogorov-Smirnov	D	0.142766 Pr > D
Cramer-von Mises	W-Sq	10.69502 Pr > W-Sq
Anderson-Darling	A-Sq	62.08756 Pr > A-Sq

- Jam 10:30

The ARIMA Procedure  
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.39902	0.02591	15.4	<.0001	1	y	0
AR1,2	0.11797	0.02663	4.43	<.0001	2	y	0

AR1,3	0.07783	0.02493	3.12	0.0018	4	y	0
AR1,4	0.16393	0.02417	6.78	<.0001	7	y	0
AR1,5	0.07308	0.02392	3.06	0.0023	14	y	0
AR1,6	0.08944	0.02634	3.4	0.0007	19	y	0
AR1,7	-0.06745	0.02627	-2.57	0.0103	20	y	0
NUM1	0.47621	0.03571	13.34	<.0001	0	t	0
NUM2	2497.3	30.49939	81.88	<.0001	0	D1	0
NUM3	2528.1	30.45231	83.02	<.0001	0	D2	0
NUM4	2506.8	30.49573	82.2	<.0001	0	D3	0
NUM5	2508.1	30.54095	82.12	<.0001	0	D4	0
NUM6	2517	30.55291	82.38	<.0001	0	D5	0
NUM7	2382.6	30.53329	78.03	<.0001	0	D6	0
NUM8	2061.2	30.52333	67.53	<.0001	0	D7	0
NUM9	-633.011	42.74486	-14.81	<.0001	0	DV1	0
NUM10	-401.308	37.80525	-10.62	<.0001	0	DV2	0
NUM11	-409.477	48.67298	-8.41	<.0001	0	DV3	0
NUM12	-417.958	42.12217	-9.92	<.0001	0	DV4	0
NUM13	-363.885	42.35304	-8.59	<.0001	0	DV5	0
NUM14	-505.592	59.62727	-8.48	<.0001	0	DV6	0
NUM15	-232.463	42.53601	-5.47	<.0001	0	DV7	0
NUM16	-222.581	48.74241	-4.57	<.0001	0	DV8	0
NUM17	-233.544	42.4641	-5.5	<.0001	0	DV9	0
NUM18	-624.736	48.71487	-12.82	<.0001	0	DV10	0
NUM19	-172.081	45.56053	-3.78	0.0002	0	DV11	0
NUM20	-490.759	48.23516	-10.17	<.0001	0	DV12	0
NUM21	-850.227	49.38253	-17.22	<.0001	0	DV13	0
NUM22	-1168.5	49.87048	-23.43	<.0001	0	DV14	0
NUM23	-996.187	49.74758	-20.02	<.0001	0	DV15	0
NUM24	-790.448	49.36119	-16.01	<.0001	0	DV16	0
NUM25	-653.503	48.20956	-13.56	<.0001	0	DV17	0
NUM26	-406.529	45.52725	-8.93	<.0001	0	DV18	0
NUM27	-842.724	48.75476	-17.28	<.0001	0	DV19	0
NUM28	-488.766	48.72318	-10.03	<.0001	0	DV20	0
NUM29	-477.723	49.04448	-9.74	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To	Chi-	DF	Pr >	-----Autocorrelations-----					
Lag	Square		ChiSq						
6	.	0	.	-0.003	-0.024	0.016	0.007	-0.02	0.013
12	7.55	5	0.183	-0.005	-0.032	0.032	0.036	0.011	-0.016
18	11.43	11	0.4078	-0.006	-0.012	0.004	0.038	0.025	-0.018
24	25.19	17	0.0905	0.015	-0.019	0.018	0.043	-0.019	0.079
30	27.75	23	0.2254	0.005	-0.023	0.019	0.022	-0.003	-0.017
36	32.91	29	0.2816	0.002	-0.014	-0.028	0.045	-0.015	-0.015
42	40.19	35	0.251	-0.022	-0.046	0.045	-0.009	-0.012	-0.004
48	43.42	41	0.3686	0.01	0.041	-0.006	0.003	-0.018	-0.004

Test	Tests for Normality			
	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.764585	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.133061	Pr > D	<0.0100
Cramer-von Mises	W-Sq	10.89064	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	63.30825	Pr > A-Sq	<0.0050

- Jam 11:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.35461	0.0259	13.69	<.0001	1	y	0
AR1,2	0.12047	0.02685	4.49	<.0001	2	y	0
AR1,3	0.07462	0.02502	2.98	0.0029	4	y	0
AR1,4	0.15495	0.02542	6.09	<.0001	7	y	0
AR1,5	0.07378	0.02516	2.93	0.0034	9	y	0
AR1,6	0.07135	0.02384	2.99	0.0028	14	y	0
NUM1	0.47772	0.03732	12.8	<.0001	0	t	0
NUM2	2518.6	31.8563	79.06	<.0001	0	D1	0
NUM3	2541.3	31.80746	79.9	<.0001	0	D2	0
NUM4	2527.9	31.84637	79.38	<.0001	0	D3	0
NUM5	2526.7	31.90062	79.21	<.0001	0	D4	0
NUM6	2542.5	31.91412	79.67	<.0001	0	D5	0
NUM7	2406.6	31.89459	75.45	<.0001	0	D6	0
NUM8	2067	31.87471	64.85	<.0001	0	D7	0
NUM9	-671.28	46.67832	-14.38	<.0001	0	DV1	0
NUM10	-423.346	41.53003	-10.19	<.0001	0	DV2	0
NUM11	-428.731	53.38181	-8.03	<.0001	0	DV3	0
NUM12	-430.395	46.22854	-9.31	<.0001	0	DV4	0
NUM13	-365.782	46.82301	-7.81	<.0001	0	DV5	0
NUM14	-529.787	65.42802	-8.1	<.0001	0	DV6	0
NUM15	-250.033	46.61209	-5.36	<.0001	0	DV7	0
NUM16	-232.921	53.46244	-4.36	<.0001	0	DV8	0
NUM17	-262.697	46.56464	-5.64	<.0001	0	DV9	0
NUM18	-654.371	53.49124	-12.23	<.0001	0	DV10	0
NUM19	-183.478	49.13262	-3.73	0.0002	0	DV11	0
NUM20	-510.411	51.32468	-9.94	<.0001	0	DV12	0
NUM21	-869.882	52.19004	-16.67	<.0001	0	DV13	0
NUM22	-1213.2	52.33786	-23.18	<.0001	0	DV14	0
NUM23	-1032.7	52.29394	-19.75	<.0001	0	DV15	0
NUM24	-838.831	52.1867	-16.07	<.0001	0	DV16	0
NUM25	-684.874	51.31072	-13.35	<.0001	0	DV17	0
NUM26	-439.324	49.12131	-8.94	<.0001	0	DV18	0
NUM27	-820.721	53.45531	-15.35	<.0001	0	DV19	0
NUM28	-499.575	53.40245	-9.35	<.0001	0	DV20	0
NUM29	-498.117	53.84726	-9.25	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.005	-0.018	0.036	-0.001	-0.009	0.01
12	5.58	6	0.4714	0	-0.019	-0.014	0.011	0.03	-0.019
18	7.4	12	0.8302	0.001	-0.007	-0.006	0.025	0.023	0.003
24	22.63	18	0.2051	0.054	-0.044	0.029	0.029	-0.012	0.06
30	24.02	24	0.4603	-0.004	-0.014	0.013	0.005	0	-0.023
36	28.36	30	0.5512	-0.01	0.009	-0.031	0.033	-0.019	-0.017
42	30.48	36	0.728	-0.013	-0.023	0.022	-0.006	-0.011	0.01
48	35.99	42	0.731	0.019	0.051	-0.019	-0.012	-0.014	0.004

Tests for Normality			
Test	---Statistic---	-----p Value-----	
Shapiro-Wilk	W	0.736594	Pr < W <0.0001
Kolmogorov-Smirnov	D	0.145878	Pr > D <0.0100
Cramer-von Mises	W-Sq	11.94269	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	68.71308	Pr > A-Sq <0.0050

- Jam 11:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.35388	0.02561	13.82	<.0001	1	y	0
AR1,2	0.16889	0.02659	6.35	<.0001	2	y	0
AR1,3	0.07501	0.02522	2.97	0.003	4	y	0
AR1,4	0.17358	0.02439	7.12	<.0001	7	y	0
AR1,5	0.07991	0.02339	3.42	0.0007	14	y	0
NUM1	0.47757	0.03738	12.77	<.0001	0	t	0
NUM2	2519.9	31.98009	78.79	<.0001	0	D1	0
NUM3	2538	31.9314	79.48	<.0001	0	D2	0
NUM4	2523.6	31.97388	78.93	<.0001	0	D3	0
NUM5	2523.4	32.02956	78.78	<.0001	0	D4	0
NUM6	2494.5	32.0429	77.85	<.0001	0	D5	0
NUM7	2408.6	32.02421	75.21	<.0001	0	D6	0
NUM8	2065.9	32.00284	64.55	<.0001	0	D7	0
NUM9	-658.878	45.74634	-14.4	<.0001	0	DV1	0
NUM10	-427.659	40.56686	-10.54	<.0001	0	DV2	0
NUM11	-440.508	52.1884	-8.44	<.0001	0	DV3	0
NUM12	-437.531	45.19455	-9.68	<.0001	0	DV4	0
NUM13	-359.728	45.41474	-7.92	<.0001	0	DV5	0
NUM14	-516.049	63.96594	-8.07	<.0001	0	DV6	0
NUM15	-260.333	45.65766	-5.7	<.0001	0	DV7	0
NUM16	-233.472	52.26007	-4.47	<.0001	0	DV8	0
NUM17	-264.694	45.59637	-5.81	<.0001	0	DV9	0
NUM18	-645.27	52.26922	-12.35	<.0001	0	DV10	0

NUM19	-173.848	48.43752	-3.59	0.0003	0	DV11	0
NUM20	-488.969	50.4343	-9.7	<.0001	0	DV12	0
NUM21	-839.489	51.82063	-16.2	<.0001	0	DV13	0
NUM22	-1145.2	52.0606	-22	<.0001	0	DV14	0
NUM23	-990.995	52.02673	-19.05	<.0001	0	DV15	0
NUM24	-791.283	51.81629	-15.27	<.0001	0	DV16	0
NUM25	-659.376	50.40822	-13.08	<.0001	0	DV17	0
NUM26	-402.751	48.41215	-8.32	<.0001	0	DV18	0
NUM27	-811.275	52.27096	-15.52	<.0001	0	DV19	0
NUM28	-504.149	52.20989	-9.66	<.0001	0	DV20	0
NUM29	-480.203	52.65828	-9.12	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.37	1	0.1237	-0.009	-0.023	0.022	-0.007	0.01	-0.02
12	7.78	7	0.3523	-0.016	-0.026	0.037	0.029	0.022	-0.007
18	8.92	13	0.7788	0.011	-0.01	-0.001	0.013	0.02	0
24	23.52	19	0.2152	0.044	-0.034	0.023	0.043	-0.016	0.064
30	25.79	25	0.419	-0.011	-0.015	0.019	0.01	-0.005	-0.027
36	30.13	31	0.5106	0	-0.002	-0.018	0.042	-0.016	-0.024
42	32.61	37	0.6749	-0.003	-0.029	0.026	-0.01	-0.004	0
48	39.31	43	0.632	0.004	0.064	-0.016	-0.003	-0.01	-0.001

Tests for Normality			
Test	---Statistic---	-----p Value-----	
Shapiro-Wilk	W	0.755959	Pr < W <0.0001
Kolmogorov-Smirnov	D	0.13757	Pr > D <0.0100
Cramer-von Mises	W-Sq	10.64713	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	61.78616	Pr > A-Sq <0.0050

- Jam 12:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.38251	0.02535	15.09	<.0001	1	y	0
AR1,2	0.20654	0.02563	8.06	<.0001	2	y	0
AR1,3	0.17774	0.02337	7.61	<.0001	7	y	0
AR1,4	0.0942	0.02274	4.14	<.0001	14	y	0
NUM1	0.46555	0.03658	12.73	<.0001	0	t	0
NUM2	2445.3	31.1588	78.48	<.0001	0	D1	0
NUM3	2456.6	31.11048	78.97	<.0001	0	D2	0
NUM4	2444.3	31.15508	78.45	<.0001	0	D3	0
NUM5	2446.4	31.21859	78.36	<.0001	0	D4	0
NUM6	2365.4	31.2425	75.71	<.0001	0	D5	0
NUM7	2347	31.21794	75.18	<.0001	0	D6	0

NUM8	2050.2	31.18771	65.74	<.0001	0	D7	0
NUM9	-595.768	41.64316	-14.31	<.0001	0	DV1	0
NUM10	-395.491	36.90804	-10.72	<.0001	0	DV2	0
NUM11	-391.87	47.49514	-8.25	<.0001	0	DV3	0
NUM12	-416.631	41.11829	-10.13	<.0001	0	DV4	0
NUM13	-318.179	41.32064	-7.7	<.0001	0	DV5	0
NUM14	-452.297	58.21887	-7.77	<.0001	0	DV6	0
NUM15	-240.638	41.6478	-5.78	<.0001	0	DV7	0
NUM16	-229.39	47.55408	-4.82	<.0001	0	DV8	0
NUM17	-227.658	41.59654	-5.47	<.0001	0	DV9	0
NUM18	-571.455	47.5395	-12.02	<.0001	0	DV10	0
NUM19	-148.226	44.63793	-3.32	0.0009	0	DV11	0
NUM20	-442.868	47.01408	-9.42	<.0001	0	DV12	0
NUM21	-779.136	48.94891	-15.92	<.0001	0	DV13	0
NUM22	-1034.9	49.44203	-20.93	<.0001	0	DV14	0
NUM23	-924.606	49.43154	-18.7	<.0001	0	DV15	0
NUM24	-723.475	48.94045	-14.78	<.0001	0	DV16	0
NUM25	-605.102	46.98288	-12.88	<.0001	0	DV17	0
NUM26	-341.646	44.62386	-7.66	<.0001	0	DV18	0
NUM27	-693.835	47.55237	-14.59	<.0001	0	DV19	0
NUM28	-449.415	47.49713	-9.46	<.0001	0	DV20	0
NUM29	-422.82	47.90509	-8.83	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.76	2	0.0928	-0.012	-0.039	0.007	0.008	0.039	0.002
12	11.41	8	0.1795	-0.021	-0.028	0.048	0.021	0.023	0.003
18	13.9	14	0.4569	0.035	-0.004	-0.005	0.004	0.005	0.02
24	26.78	20	0.1415	0.055	-0.021	0.012	0.04	-0.02	0.055
30	29.5	26	0.289	-0.01	-0.017	0.014	0.022	-0.016	-0.023
36	32.81	32	0.4271	-0.006	0.012	-0.018	0.026	-0.012	-0.03
42	33.81	38	0.6638	0.006	-0.017	0.015	0.004	-0.006	-0.008
48	39.19	44	0.6776	0.003	0.056	-0.021	-0.003	0.003	0.001

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.777858 Pr < W <0.0001
Kolmogorov-Smirnov	D	0.124038 Pr > D <0.0100
Cramer-von Mises	W-Sq	8.444837 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	49.62127 Pr > A-Sq <0.0050

- Jam 12:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.40973	0.02541	16.12	<.0001	1	y	0
AR1,2	0.19267	0.02583	7.46	<.0001	2	y	0
AR1,3	0.17599	0.02311	7.61	<.0001	7	y	0
AR1,4	0.08714	0.02248	3.88	0.0001	14	y	0
NUM1	0.4667	0.03671	12.71	<.0001	0	t	0
NUM2	2421.2	31.18161	77.65	<.0001	0	D1	0
NUM3	2431	31.13264	78.09	<.0001	0	D2	0
NUM4	2423.9	31.18032	77.74	<.0001	0	D3	0
NUM5	2427	31.24238	77.68	<.0001	0	D4	0
NUM6	2333.8	31.26683	74.64	<.0001	0	D5	0
NUM7	2316.3	31.24221	74.14	<.0001	0	D6	0
NUM8	2042.4	31.21258	65.44	<.0001	0	D7	0
NUM9	-585.768	40.24691	-14.55	<.0001	0	DV1	0
NUM10	-388.611	35.68608	-10.89	<.0001	0	DV2	0
NUM11	-393.131	45.9094	-8.56	<.0001	0	DV3	0
NUM12	-394.617	39.74587	-9.93	<.0001	0	DV4	0
NUM13	-331.336	39.9531	-8.29	<.0001	0	DV5	0
NUM14	-455.057	56.26686	-8.09	<.0001	0	DV6	0
NUM15	-239.905	40.24949	-5.96	<.0001	0	DV7	0
NUM16	-241.406	45.96696	-5.25	<.0001	0	DV8	0
NUM17	-240.766	40.2293	-5.98	<.0001	0	DV9	0
NUM18	-551.976	45.95477	-12.01	<.0001	0	DV10	0
NUM19	-150.186	43.39301	-3.46	0.0006	0	DV11	0
NUM20	-428.415	46.09617	-9.29	<.0001	0	DV12	0
NUM21	-753.181	48.03838	-15.68	<.0001	0	DV13	0
NUM22	-993.613	48.57745	-20.45	<.0001	0	DV14	0
NUM23	-901.033	48.57304	-18.55	<.0001	0	DV15	0
NUM24	-711.245	48.03763	-14.81	<.0001	0	DV16	0
NUM25	-590.197	46.0743	-12.81	<.0001	0	DV17	0
NUM26	-335.408	43.38412	-7.73	<.0001	0	DV18	0
NUM27	-683.2	45.97703	-14.86	<.0001	0	DV19	0
NUM28	-433.496	45.90553	-9.44	<.0001	0	DV20	0
NUM29	-403.587	46.31406	-8.71	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.32	2	0.0701	-0.009	-0.034	-0.002	0.006	0.048	-0.006
12	10.89	8	0.2078	-0.019	-0.024	0.043	0.013	0.01	0.027
18	13.48	14	0.4889	0.032	-0.003	-0.004	-0.003	0.004	0.027
24	25.09	20	0.1979	0.058	-0.029	0.017	0.035	-0.01	0.044
30	28.18	26	0.3497	0.002	-0.026	0.011	0.022	-0.004	-0.028
36	34.03	32	0.37	-0.007	0.001	-0.026	0.034	-0.009	-0.044



42	35.17	38	0.6009	0.006	-0.01	0.008	0.015	-0.016	-0.007
48	40.77	44	0.611	0.016	0.052	-0.019	0.015	0.002	-0.01

Tests for Normality				
Test	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.789758	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.114632	Pr > D	<0.0100
Cramer-von Mises	W-Sq	7.587978	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	45.20688	Pr > A-Sq	<0.0050

- Jam 13:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.38822	0.02616	14.84	<.0001	1	y	0
AR1,2	0.14248	0.0278	5.12	<.0001	2	y	0
AR1,3	0.06015	0.0263	2.29	0.0223	3	y	0
AR1,4	0.17986	0.02384	7.55	<.0001	7	y	0
AR1,5	0.07753	0.02313	3.35	0.0008	14	y	0
NUM1	0.47717	0.03602	13.25	<.0001	0	t	0
NUM2	2489.7	30.86045	80.68	<.0001	0	D1	0
NUM3	2497.5	30.81291	81.06	<.0001	0	D2	0
NUM4	2489.6	30.85738	80.68	<.0001	0	D3	0
NUM5	2493.2	30.91088	80.66	<.0001	0	D4	0
NUM6	2459.6	30.93673	79.5	<.0001	0	D5	0
NUM7	2334.3	30.90837	75.52	<.0001	0	D6	0
NUM8	2048.2	30.8863	66.31	<.0001	0	D7	0
NUM9	-637.071	44.34788	-14.37	<.0001	0	DV1	0
NUM10	-429.825	39.32435	-10.93	<.0001	0	DV2	0
NUM11	-455.326	50.56926	-9	<.0001	0	DV3	0
NUM12	-415.455	43.80038	-9.49	<.0001	0	DV4	0
NUM13	-409.702	44.00551	-9.31	<.0001	0	DV5	0
NUM14	-521.254	61.96547	-8.41	<.0001	0	DV6	0
NUM15	-269.92	44.17182	-6.11	<.0001	0	DV7	0
NUM16	-257.446	50.64218	-5.08	<.0001	0	DV8	0
NUM17	-263.794	44.16306	-5.97	<.0001	0	DV9	0
NUM18	-607.131	50.65037	-11.99	<.0001	0	DV10	0
NUM19	-167.603	47.28453	-3.54	0.0004	0	DV11	0
NUM20	-462.995	49.79879	-9.3	<.0001	0	DV12	0
NUM21	-788.766	51.16676	-15.42	<.0001	0	DV13	0
NUM22	-1056.2	51.79395	-20.39	<.0001	0	DV14	0
NUM23	-960.911	51.77976	-18.56	<.0001	0	DV15	0
NUM24	-753.341	51.15053	-14.73	<.0001	0	DV16	0
NUM25	-635.64	49.77597	-12.77	<.0001	0	DV17	0
NUM26	-380.762	47.26474	-8.06	<.0001	0	DV18	0
NUM27	-758.145	50.69135	-14.96	<.0001	0	DV19	0

NUM28	-476.095	50.55909	-9.42	<.0001	0	DV20	0
NUM29	-447.063	51.06309	-8.76	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.74	1	0.0979	-0.005	-0.019	-0.029	0.004	0.015	0.021
12	9.21	7	0.238	-0.016	-0.034	0.036	0.011	0.039	-0.008
18	12.5	13	0.487	0.032	-0.019	0.011	0	0.016	0.022
24	23.49	19	0.2163	0.035	-0.024	0.015	0.049	-0.008	0.054
30	28.96	25	0.2656	-0.019	-0.016	0.01	0.036	-0.007	-0.04
36	32.01	31	0.4163	-0.003	0.002	-0.01	0.021	-0.012	-0.036
42	33.55	37	0.6316	0.016	-0.005	0.025	0.002	-0.009	-0.004
48	39.14	43	0.6392	0.011	0.05	-0.015	0.021	-0.019	-0.001

Tests for Normality			
Test	---Statistic---	-----p Value-----	
Shapiro-Wilk	W	0.780771	Pr < W <0.0001
Kolmogorov-Smirnov	D	0.119328	Pr > D <0.0100
Cramer-von Mises	W-Sq	8.479706	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	50.18965	Pr > A-Sq <0.0050

• Jam 13:30

The ARIMA Procedure Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.3978	0.02574	15.46	<.0001	1	y	0
AR1,2	0.14456	0.02563	5.64	<.0001	2	y	0
AR1,3	0.19202	0.02365	8.12	<.0001	7	y	0
AR1,4	0.09739	0.02311	4.21	<.0001	14	y	0
NUM1	0.49042	0.03523	13.92	<.0001	0	t	0
NUM2	2569.6	30.52625	84.18	<.0001	0	D1	0
NUM3	2580.3	30.47806	84.66	<.0001	0	D2	0
NUM4	2572.2	30.5283	84.26	<.0001	0	D3	0
NUM5	2572.6	30.59428	84.09	<.0001	0	D4	0
NUM6	2555.1	30.62002	83.45	<.0001	0	D5	0
NUM7	2371.5	30.59157	77.52	<.0001	0	D6	0
NUM8	2060	30.56045	67.41	<.0001	0	D7	0
NUM9	-692.741	47.394	-14.62	<.0001	0	DV1	0
NUM10	-459.188	42.04379	-10.92	<.0001	0	DV2	0
NUM11	-518.446	54.03973	-9.59	<.0001	0	DV3	0
NUM12	-459.45	46.8059	-9.82	<.0001	0	DV4	0
NUM13	-444.752	47.0177	-9.46	<.0001	0	DV5	0
NUM14	-592.025	66.23478	-8.94	<.0001	0	DV6	0
NUM15	-286.688	47.27166	-6.06	<.0001	0	DV7	0
NUM16	-278.067	54.12211	-5.14	<.0001	0	DV8	0

NUM17	-303.443	47.26284	-6.42	<.0001	0	DV9	0
NUM18	-696.592	54.12353	-12.87	<.0001	0	DV10	0
NUM19	-191.658	50.73458	-3.78	0.0002	0	DV11	0
NUM20	-523.069	53.68692	-9.74	<.0001	0	DV12	0
NUM21	-862.851	55.24847	-15.62	<.0001	0	DV13	0
NUM22	-1155.6	55.64856	-20.77	<.0001	0	DV14	0
NUM23	-1074.6	55.63647	-19.31	<.0001	0	DV15	0
NUM24	-847.466	55.2565	-15.34	<.0001	0	DV16	0
NUM25	-689.903	53.66146	-12.86	<.0001	0	DV17	0
NUM26	-428.172	50.70961	-8.44	<.0001	0	DV18	0
NUM27	-829.407	54.15529	-15.32	<.0001	0	DV19	0
NUM28	-536.973	54.07053	-9.93	<.0001	0	DV20	0
NUM29	-505.119	54.59668	-9.25	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	4.53	2	0.104	-0.011	-0.039	0.024	0.018	0.017	0.017
12	11.32	8	0.1841	-0.013	-0.019	0.009	0.029	0.053	-0.018
18	13.44	14	0.4919	0.027	-0.009	-0.008	-0.006	0.018	0.015
24	24.09	20	0.2384	0.025	-0.02	0.032	0.051	-0.012	0.049
30	27.65	26	0.376	-0.009	-0.015	0.007	0.025	0	-0.037
36	30.22	32	0.557	-0.002	-0.004	-0.011	0.022	0	-0.033
42	33.11	38	0.6947	0.004	-0.016	0.039	0	-0.007	0.01
48	39.75	44	0.6541	0.005	0.046	-0.008	0.035	-0.03	-0.002

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.785897 Pr < W <.0001
Kolmogorov-Smirnov	D	0.124531 Pr > D <.0100
Cramer-von Mises	W-Sq	9.244936 Pr > W-Sq <.00050
Anderson-Darling	A-Sq	54.56255 Pr > A-Sq <.00050

- Jam 14:00

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.40445	0.0258	15.68	<.0001	1	y	0
AR1,2	0.14104	0.02563	5.5	<.0001	2	y	0
AR1,3	0.18487	0.0235	7.87	<.0001	7	y	0
AR1,4	0.09961	0.02304	4.32	<.0001	14	y	0
NUM1	0.48522	0.03406	14.25	<.0001	0	t	0
NUM2	2558.3	29.53094	86.63	<.0001	0	D1	0
NUM3	2569.5	29.48404	87.15	<.0001	0	D2	0
NUM4	2559.8	29.53279	86.68	<.0001	0	D3	0
NUM5	2561.9	29.59648	86.56	<.0001	0	D4	0

NUM6	2541.1	29.62139	85.78	<.0001	0	D5	0
NUM7	2352.7	29.59378	79.5	<.0001	0	D6	0
NUM8	2053.9	29.56395	69.47	<.0001	0	D7	0
NUM9	-688.943	46.17444	-14.92	<.0001	0	DV1	0
NUM10	-434.451	41.05024	-10.58	<.0001	0	DV2	0
NUM11	-513.999	52.65468	-9.76	<.0001	0	DV3	0
NUM12	-445.895	45.59472	-9.78	<.0001	0	DV4	0
NUM13	-449.336	45.8142	-9.81	<.0001	0	DV5	0
NUM14	-571.551	64.54781	-8.85	<.0001	0	DV6	0
NUM15	-295.932	46.06142	-6.42	<.0001	0	DV7	0
NUM16	-273.847	52.73829	-5.19	<.0001	0	DV8	0
NUM17	-290.35	46.04796	-6.31	<.0001	0	DV9	0
NUM18	-687.053	52.72976	-13.03	<.0001	0	DV10	0
NUM19	-194.544	49.48732	-3.93	<.0001	0	DV11	0
NUM20	-531.247	52.52932	-10.11	<.0001	0	DV12	0
NUM21	-849.06	54.08546	-15.7	<.0001	0	DV13	0
NUM22	-1153.6	54.49333	-21.17	<.0001	0	DV14	0
NUM23	-1070.5	54.48125	-19.65	<.0001	0	DV15	0
NUM24	-847.702	54.09512	-15.67	<.0001	0	DV16	0
NUM25	-695.225	52.49935	-13.24	<.0001	0	DV17	0
NUM26	-431.56	49.46811	-8.72	<.0001	0	DV18	0
NUM27	-804.378	52.76067	-15.25	<.0001	0	DV19	0
NUM28	-541.904	52.66581	-10.29	<.0001	0	DV20	0
NUM29	-500.867	53.17268	-9.42	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.24	2	0.3257	-0.008	-0.027	0.017	0.011	0.004	0.017
12	7.35	8	0.4989	-0.012	-0.016	0.006	0.021	0.048	-0.016
18	9.05	14	0.8281	0.025	-0.009	-0.001	-0.015	0.015	0.005
24	18.94	20	0.5258	0.016	-0.011	0.036	0.051	-0.019	0.044
30	22.05	26	0.6861	-0.002	-0.011	0.006	0.031	-0.005	-0.031
36	25.83	32	0.771	-0.007	-0.004	-0.011	0.03	0.001	-0.038
42	26.97	38	0.909	0.004	-0.004	0.024	0.002	0.012	0.005
48	35.94	44	0.8013	0.003	0.06	0.003	0.031	-0.037	-0.004

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.798629 Pr < W <0.0001
Kolmogorov-Smirnov	D	0.131098 Pr > D <0.0100
Cramer-von Mises	W-Sq	9.356893 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	54.10079 Pr > A-Sq <0.0050

- Jam 14:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.41348	0.02586	15.99	<.0001	1	y	0
AR1,2	0.13069	0.02573	5.08	<.0001	2	y	0
AR1,3	0.18522	0.02342	7.91	<.0001	7	y	0
AR1,4	0.08994	0.02305	3.9	<.0001	14	y	0
NUM1	0.47874	0.03101	15.44	<.0001	0	t	0
NUM2	2548.5	27.00721	94.37	<.0001	0	D1	0
NUM3	2558.1	26.96433	94.87	<.0001	0	D2	0
NUM4	2550.3	27.00925	94.42	<.0001	0	D3	0
NUM5	2549.8	27.06847	94.2	<.0001	0	D4	0
NUM6	2519.5	27.09144	93	<.0001	0	D5	0
NUM7	2332.5	27.06479	86.18	<.0001	0	D6	0
NUM8	2051.4	27.03734	75.87	<.0001	0	D7	0
NUM9	-669.969	44.17737	-15.17	<.0001	0	DV1	0
NUM10	-423.348	39.28293	-10.78	<.0001	0	DV2	0
NUM11	-513.128	50.38767	-10.18	<.0001	0	DV3	0
NUM12	-435.269	43.64564	-9.97	<.0001	0	DV4	0
NUM13	-440.468	43.84789	-10.05	<.0001	0	DV5	0
NUM14	-569.523	61.76142	-9.22	<.0001	0	DV6	0
NUM15	-287.748	44.06577	-6.53	<.0001	0	DV7	0
NUM16	-272.895	50.46645	-5.41	<.0001	0	DV8	0
NUM17	-283.761	44.07801	-6.44	<.0001	0	DV9	0
NUM18	-673.227	50.46853	-13.34	<.0001	0	DV10	0
NUM19	-188.479	47.46286	-3.97	<.0001	0	DV11	0
NUM20	-526.143	50.53671	-10.41	<.0001	0	DV12	0
NUM21	-832.454	52.00624	-16.01	<.0001	0	DV13	0
NUM22	-1164.5	52.39887	-22.22	<.0001	0	DV14	0
NUM23	-1084.1	52.38639	-20.69	<.0001	0	DV15	0
NUM24	-854.568	52.00595	-16.43	<.0001	0	DV16	0
NUM25	-706.742	50.50114	-13.99	<.0001	0	DV17	0
NUM26	-441.134	47.44422	-9.3	<.0001	0	DV18	0
NUM27	-770.965	50.50206	-15.27	<.0001	0	DV19	0
NUM28	-547.916	50.4077	-10.87	<.0001	0	DV20	0
NUM29	-485.794	50.89372	-9.55	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.4	2	0.3015	-0.006	-0.024	0.014	0.024	-0.009	0.013
12	6.95	8	0.5424	-0.006	-0.018	-0.009	0.003	0.051	-0.004
18	8.09	14	0.8845	0.012	-0.016	-0.001	-0.008	0.01	0.015
24	15.84	20	0.7266	0.004	-0.011	0.03	0.055	-0.011	0.032
30	20.43	26	0.7706	-0.011	0.005	-0.005	0.049	-0.009	-0.021

36	23.5	32	0.8619	-0.021	0.003	-0.012	0.029	-0.005	-0.024
42	25.73	38	0.9355	0.002	-0.005	0.029	-0.004	0.021	0.014
48	34.05	44	0.8602	-0.003	0.06	0.012	0.025	-0.034	-0.002

Test	Tests for Normality			
	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.808394	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.130288	Pr > D	<0.0100
Cramer-von Mises	W-Sq	9.154044	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	52.8906	Pr > A-Sq	<0.0050

## • Jam 15:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.43517	0.02591	16.8	<.0001	1	y	0
AR1,2	0.11376	0.02568	4.43	<.0001	2	y	0
AR1,3	0.19712	0.02328	8.47	<.0001	7	y	0
AR1,4	0.07185	0.02286	3.14	0.0017	14	y	0
NUM1	0.47377	0.02943	16.1	<.0001	0	t	0
NUM2	2535.7	25.64187	98.89	<.0001	0	D1	0
NUM3	2543.6	25.60073	99.36	<.0001	0	D2	0
NUM4	2536	25.64579	98.89	<.0001	0	D3	0
NUM5	2536.1	25.70181	98.67	<.0001	0	D4	0
NUM6	2506.5	25.72408	97.44	<.0001	0	D5	0
NUM7	2315.8	25.6985	90.11	<.0001	0	D6	0
NUM8	2056.5	25.67239	80.1	<.0001	0	D7	0
NUM9	-636.63	41.8507	-15.21	<.0001	0	DV1	0
NUM10	-403.28	37.15123	-10.86	<.0001	0	DV2	0
NUM11	-479.955	47.69169	-10.06	<.0001	0	DV3	0
NUM12	-420.137	41.29963	-10.17	<.0001	0	DV4	0
NUM13	-432.167	41.50497	-10.41	<.0001	0	DV5	0
NUM14	-557.821	58.43517	-9.55	<.0001	0	DV6	0
NUM15	-283.961	41.69168	-6.81	<.0001	0	DV7	0
NUM16	-246.379	47.7585	-5.16	<.0001	0	DV8	0
NUM17	-281.251	41.68986	-6.75	<.0001	0	DV9	0
NUM18	-642.235	47.77784	-13.44	<.0001	0	DV10	0
NUM19	-152.87	45.20282	-3.38	0.0007	0	DV11	0
NUM20	-473.066	48.43126	-9.77	<.0001	0	DV12	0
NUM21	-793.184	49.82846	-15.92	<.0001	0	DV13	0
NUM22	-1160.6	50.20982	-23.11	<.0001	0	DV14	0
NUM23	-1085.2	50.19397	-21.62	<.0001	0	DV15	0
NUM24	-858.588	49.8198	-17.23	<.0001	0	DV16	0
NUM25	-711.218	48.37965	-14.7	<.0001	0	DV17	0
NUM26	-441.94	45.18676	-9.78	<.0001	0	DV18	0
NUM27	-741.761	47.81293	-15.51	<.0001	0	DV19	0

NUM28	-524.673	47.70954	-11	<.0001	0	DV20	0
NUM29	-458.419	48.23366	-9.5	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	3.82	2	0.148	0.002	-0.022	0.026	0.027	-0.023	0.014
12	11.93	8	0.1541	0.014	-0.05	-0.008	-0.007	0.048	-0.022
18	13.32	14	0.5015	0.016	-0.019	0.01	-0.009	0.008	0.009
24	18.58	20	0.5491	0	-0.012	0.027	0.049	-0.008	0.016
30	26.75	26	0.4224	-0.018	-0.017	-0.004	0.062	-0.012	-0.029
36	31.3	32	0.5017	-0.012	-0.009	-0.022	0.04	-0.006	-0.027
42	35.32	38	0.594	0.008	0	0.039	0.013	0.027	0.012
48	44.41	44	0.4546	0.002	0.064	0.017	0.022	-0.033	-0.007

Tests for Normality				
Test	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.813133	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.132981	Pr > D	<0.0100
Cramer-von Mises	W-Sq	9.341742	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	53.8892	Pr > A-Sq	<0.0050

- Jam 15:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.47836	0.02663	17.97	<.0001	1	y	0
AR1,2	0.09283	0.02866	3.24	0.0012	2	y	0
AR1,3	0.05156	0.02611	1.97	0.0485	3	y	0
AR1,4	0.24445	0.02601	9.4	<.0001	7	y	0
AR1,5	-0.0723	0.02642	-2.74	0.0063	8	y	0
NUM1	0.47364	0.02631	18	<.0001	0	t	0
NUM2	2553.9	23.09225	110.59	<.0001	0	D1	0
NUM3	2560.8	23.05729	111.06	<.0001	0	D2	0
NUM4	2550.2	23.09345	110.43	<.0001	0	D3	0
NUM5	2550.9	23.13751	110.25	<.0001	0	D4	0
NUM6	2523.1	23.15777	108.95	<.0001	0	D5	0
NUM7	2327.3	23.13094	100.61	<.0001	0	D6	0
NUM8	2088.9	23.11366	90.37	<.0001	0	D7	0
NUM9	-629.956	40.48493	-15.56	<.0001	0	DV1	0
NUM10	-396.623	35.60737	-11.14	<.0001	0	DV2	0
NUM11	-466.52	45.69805	-10.21	<.0001	0	DV3	0
NUM12	-404.899	39.58813	-10.23	<.0001	0	DV4	0
NUM13	-409.004	39.76008	-10.29	<.0001	0	DV5	0
NUM14	-537.746	55.9664	-9.61	<.0001	0	DV6	0
NUM15	-273.444	39.90067	-6.85	<.0001	0	DV7	0

NUM16	-256.45	45.75552	-5.6	<.0001	0	DV8	0
NUM17	-269.1	39.8784	-6.75	<.0001	0	DV9	0
NUM18	-625.052	45.82521	-13.64	<.0001	0	DV10	0
NUM19	-130.197	44.54059	-2.92	0.0035	0	DV11	0
NUM20	-401.854	47.95839	-8.38	<.0001	0	DV12	0
NUM21	-725.475	49.52191	-14.65	<.0001	0	DV13	0
NUM22	-1134	50.25571	-22.56	<.0001	0	DV14	0
NUM23	-1047.2	50.25351	-20.84	<.0001	0	DV15	0
NUM24	-835.399	49.57877	-16.85	<.0001	0	DV16	0
NUM25	-690.932	47.93443	-14.41	<.0001	0	DV17	0
NUM26	-424.164	44.51689	-9.53	<.0001	0	DV18	0
NUM27	-718.943	45.79905	-15.7	<.0001	0	DV19	0
NUM28	-487.57	45.71231	-10.67	<.0001	0	DV20	0
NUM29	-463.029	46.68533	-9.92	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.33	1	0.2487	-0.001	0	-0.006	0.013	-0.022	0.015
12	7.85	7	0.3456	-0.016	-0.013	-0.013	-0.025	0.044	-0.035
18	12.51	13	0.4867	0	0.044	0.032	0.003	0.003	0.014
24	18.07	19	0.518	0.009	-0.027	0.026	0.046	0.001	0.013
30	23.27	25	0.5617	-0.011	-0.03	0.003	0.039	-0.005	-0.03
36	27.13	31	0.6658	-0.005	-0.008	-0.037	0.014	-0.006	-0.03
42	33.07	37	0.654	0.02	0.012	0.044	0.025	0.027	0.011
48	43.34	43	0.457	-0.002	0.072	-0.007	0.023	-0.03	0.006

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.82818 Pr < W <0.0001
Kolmogorov-Smirnov	D	0.126341 Pr > D <0.0100
Cramer-von Mises	W-Sq	8.387152 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	49.22315 Pr > A-Sq <0.0050

## • Jam 16:00

The ARIMA Procedure  
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.49984	0.02661	18.78	<.0001	1	y	0
AR1,2	0.10004	0.02901	3.45	0.0006	2	y	0
AR1,3	0.07516	0.02644	2.84	0.0045	3	y	0
AR1,4	0.21434	0.0263	8.15	<.0001	7	y	0
AR1,5	-0.07596	0.02632	-2.89	0.004	8	y	0
NUM1	0.45423	0.02759	16.46	<.0001	0	t	0
NUM2	2564.8	23.9475	107.1	<.0001	0	D1	0
NUM3	2570.3	23.91129	107.49	<.0001	0	D2	0



NUM4	2558.4	23.94697	106.84	<.0001	0	D3	0
NUM5	2556.1	23.98711	106.56	<.0001	0	D4	0
NUM6	2540.2	24.00785	105.81	<.0001	0	D5	0
NUM7	2353.6	23.98182	98.14	<.0001	0	D6	0
NUM8	2144.6	23.96703	89.48	<.0001	0	D7	0
NUM9	-596.768	38.50188	-15.5	<.0001	0	DV1	0
NUM10	-375.39	33.92435	-11.07	<.0001	0	DV2	0
NUM11	-413.148	43.55705	-9.49	<.0001	0	DV3	0
NUM12	-367.128	37.72596	-9.73	<.0001	0	DV4	0
NUM13	-366.091	37.955	-9.65	<.0001	0	DV5	0
NUM14	-493.277	53.35367	-9.25	<.0001	0	DV6	0
NUM15	-269.728	38.03993	-7.09	<.0001	0	DV7	0
NUM16	-260.223	43.61378	-5.97	<.0001	0	DV8	0
NUM17	-245.708	37.99391	-6.47	<.0001	0	DV9	0
NUM18	-568.295	43.66707	-13.01	<.0001	0	DV10	0
NUM19	-87.4462	42.76136	-2.04	0.041	0	DV11	0
NUM20	-351.56	46.53084	-7.56	<.0001	0	DV12	0
NUM21	-693.108	48.31555	-14.35	<.0001	0	DV13	0
NUM22	-1102.2	49.32786	-22.34	<.0001	0	DV14	0
NUM23	-1028.7	49.35672	-20.84	<.0001	0	DV15	0
NUM24	-800.819	48.41934	-16.54	<.0001	0	DV16	0
NUM25	-661.693	46.54305	-14.22	<.0001	0	DV17	0
NUM26	-402.24	42.74288	-9.41	<.0001	0	DV18	0
NUM27	-629.757	43.68315	-14.42	<.0001	0	DV19	0
NUM28	-443.59	43.56627	-10.18	<.0001	0	DV20	0
NUM29	-446.883	43.35762	-10.07	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	0.42	1	0.5151	-0.003	0	-0.007	0.011	0	0.011
12	11.18	7	0.1309	-0.008	-0.001	-0.015	-0.023	0.058	-0.055
18	15.03	13	0.3058	-0.003	0.035	0.012	0.032	-0.011	0.006
24	21	19	0.3371	0.009	-0.031	0.026	0.044	-0.019	0.001
30	27.22	25	0.3451	-0.01	-0.041	0.016	0.015	-0.016	-0.041
36	34.18	31	0.3174	0	-0.023	-0.034	0.004	-0.022	-0.049
42	43.37	37	0.2181	0.04	0.017	0.047	0.037	0.026	0.003
48	48.55	43	0.2591	0.006	0.048	-0.006	0.013	-0.029	0.003

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.853915 Pr < W <.0001
Kolmogorov-Smirnov	D	0.11375 Pr > D <0.0100
Cramer-von Mises	W-Sq	6.970535 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	41.78352 Pr > A-Sq <0.0050

- Jam 16:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.40886	0.02629	15.55	<.0001	1	y	0
AR1,2	0.13241	0.02818	4.7	<.0001	2	y	0
AR1,3	0.09294	0.02646	3.51	0.0005	3	y	0
AR1,4	0.15642	0.02292	6.82	<.0001	7	y	0
NUM1	0.44759	0.02634	16.99	<.0001	0	t	0
NUM2	2576.3	22.95237	112.25	<.0001	0	D1	0
NUM3	2575.7	22.91767	112.39	<.0001	0	D2	0
NUM4	2566.7	22.9441	111.87	<.0001	0	D3	0
NUM5	2564	22.98544	111.55	<.0001	0	D4	0
NUM6	2555.5	23.00502	111.09	<.0001	0	D5	0
NUM7	2385.7	22.97536	103.84	<.0001	0	D6	0
NUM8	2205.7	22.9617	96.06	<.0001	0	D7	0
NUM9	-553.954	42.39324	-13.07	<.0001	0	DV1	0
NUM10	-358.982	37.61912	-9.54	<.0001	0	DV2	0
NUM11	-383.145	48.37171	-7.92	<.0001	0	DV3	0
NUM12	-342.591	41.89292	-8.18	<.0001	0	DV4	0
NUM13	-294.339	42.18885	-6.98	<.0001	0	DV5	0
NUM14	-452.97	59.26169	-7.64	<.0001	0	DV6	0
NUM15	-257.501	42.27592	-6.09	<.0001	0	DV7	0
NUM16	-248.437	48.45784	-5.13	<.0001	0	DV8	0
NUM17	-229.738	42.18149	-5.45	<.0001	0	DV9	0
NUM18	-495.451	48.447	-10.23	<.0001	0	DV10	0
NUM19	-96.1836	45.65493	-2.11	0.0353	0	DV11	0
NUM20	-331.881	48.46569	-6.85	<.0001	0	DV12	0
NUM21	-672.937	49.88153	-13.49	<.0001	0	DV13	0
NUM22	-1062.5	50.83802	-20.9	<.0001	0	DV14	0
NUM23	-970.194	50.81498	-19.09	<.0001	0	DV15	0
NUM24	-778.062	49.92815	-15.58	<.0001	0	DV16	0
NUM25	-646.553	48.41214	-13.36	<.0001	0	DV17	0
NUM26	-418.114	45.61337	-9.17	<.0001	0	DV18	0
NUM27	-592.044	48.5345	-12.2	<.0001	0	DV19	0
NUM28	-393.991	48.38616	-8.14	<.0001	0	DV20	0
NUM29	-456.023	48.81967	-9.34	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.48	2	0.4768	-0.002	-0.005	-0.022	0.015	0.015	0.008
12	6.64	8	0.5755	-0.009	-0.019	-0.032	0.026	0.017	-0.033
18	16.51	14	0.283	0.004	0.027	0.013	0.06	-0.044	0.016
24	26.55	20	0.1483	0.022	-0.002	0.066	0.027	-0.034	0.009
30	30.11	26	0.2632	-0.003	-0.026	0.015	0.011	0.006	-0.037
36	35.17	32	0.3205	-0.001	-0.017	-0.036	-0.008	-0.028	-0.031

42	47.64	38	0.1358	0.025	0.013	0.053	0.025	0.063	-0.011
48	49.78	44	0.254	0.002	0.034	-0.008	-0.006	-0.008	-0.012

Tests for Normality				
Test	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.838865	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.100988	Pr > D	<0.0100
Cramer-von Mises	W-Sq	5.719415	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	34.42127	Pr > A-Sq	<0.0050

- Jam 17:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.36839	0.02634	13.99	<.0001	1	y	0
AR1,2	0.14441	0.02783	5.19	<.0001	2	y	0
AR1,3	0.09142	0.0264	3.46	0.0005	3	y	0
AR1,4	0.14567	0.02354	6.19	<.0001	7	y	0
AR1,5	0.07324	0.02277	3.22	0.0013	16	y	0
NUM1	0.44852	0.03143	14.27	<.0001	0	t	0
NUM2	2636.8	27.0315	97.55	<.0001	0	D1	0
NUM3	2634	26.99015	97.59	<.0001	0	D2	0
NUM4	2621.8	27.01748	97.04	<.0001	0	D3	0
NUM5	2621.5	27.06207	96.87	<.0001	0	D4	0
NUM6	2609.4	27.08358	96.35	<.0001	0	D5	0
NUM7	2465.5	27.05385	91.13	<.0001	0	D6	0
NUM8	2310.6	27.039	85.46	<.0001	0	D7	0
NUM9	-516.946	44.48092	-11.62	<.0001	0	DV1	0
NUM10	-323.813	39.4614	-8.21	<.0001	0	DV2	0
NUM11	-328.168	50.78315	-6.46	<.0001	0	DV3	0
NUM12	-310.221	43.98719	-7.05	<.0001	0	DV4	0
NUM13	-245.401	44.29164	-5.54	<.0001	0	DV5	0
NUM14	-366.775	62.19937	-5.9	<.0001	0	DV6	0
NUM15	-241.332	44.39072	-5.44	<.0001	0	DV7	0
NUM16	-243.806	50.86466	-4.79	<.0001	0	DV8	0
NUM17	-223.086	44.26786	-5.04	<.0001	0	DV9	0
NUM18	-446.411	50.82482	-8.78	<.0001	0	DV10	0
NUM19	-95.064	47.32212	-2.01	0.0447	0	DV11	0
NUM20	-347	49.69134	-6.98	<.0001	0	DV12	0
NUM21	-662.964	51.02988	-12.99	<.0001	0	DV13	0
NUM22	-1010.6	51.9047	-19.47	<.0001	0	DV14	0
NUM23	-921.238	51.91155	-17.75	<.0001	0	DV15	0
NUM24	-733.934	51.04921	-14.38	<.0001	0	DV16	0
NUM25	-616.404	49.64147	-12.42	<.0001	0	DV17	0
NUM26	-399.41	47.31928	-8.44	<.0001	0	DV18	0
NUM27	-556.283	50.92257	-10.92	<.0001	0	DV19	0

NUM28	-326.324	50.80576	-6.42	<.0001	0	DV20	0
NUM29	-439.921	51.19795	-8.59	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.9	1	0.0886	-0.003	-0.009	-0.034	0.006	0.018	0.02
12	11.43	7	0.1209	-0.018	-0.002	-0.041	0.049	0.029	-0.023
18	21.3	13	0.0672	0.034	0.049	0.019	0.013	-0.05	0.002
24	31.66	19	0.0341	0.024	-0.005	0.066	0.015	-0.04	0.011
30	32.99	25	0.1312	0.006	-0.002	0.016	0.017	0.012	-0.013
36	36.76	31	0.2193	0.019	-0.003	-0.02	-0.009	-0.031	-0.026
42	48.8	37	0.0928	0.021	0.015	0.058	0.01	0.062	-0.002
48	51.64	43	0.172	-0.023	0.016	-0.03	-0.001	-0.015	0

Tests for Normality			
Test	---Statistic---	-----p Value-----	
Shapiro-Wilk	W	0.875029	Pr < W <0.0001
Kolmogorov-Smirnov	D	0.078739	Pr > D <0.0100
Cramer-von Mises	W-Sq	3.330654	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	20.46752	Pr > A-Sq <0.0050

- Jam 17:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.35859	0.0266	13.48	<.0001	1	y	0
AR1,2	0.16224	0.02785	5.83	<.0001	2	y	0
AR1,3	0.10971	0.02673	4.1	<.0001	3	y	0
AR1,4	0.09685	0.02382	4.07	<.0001	7	y	0
AR1,5	0.08756	0.02264	3.87	<.0001	18	y	0
NUM1	0.42085	0.02905	14.49	<.0001	0	t	0
NUM2	3092.4	25.08146	123.29	<.0001	0	D1	0
NUM3	3097	25.04472	123.66	<.0001	0	D2	0
NUM4	3103	25.06594	123.79	<.0001	0	D3	0
NUM5	3099.4	25.10346	123.46	<.0001	0	D4	0
NUM6	3083.4	25.11444	122.77	<.0001	0	D5	0
NUM7	2994.9	25.09055	119.37	<.0001	0	D6	0
NUM8	2914.3	25.08302	116.19	<.0001	0	D7	0
NUM9	-291.246	43.13855	-6.75	<.0001	0	DV1	0
NUM10	-232.791	38.31226	-6.08	<.0001	0	DV2	0
NUM11	-262.395	49.16786	-5.34	<.0001	0	DV3	0
NUM12	-175.003	42.55498	-4.11	<.0001	0	DV4	0
NUM13	-223.841	42.86508	-5.22	<.0001	0	DV5	0
NUM14	-279.722	60.21593	-4.65	<.0001	0	DV6	0
NUM15	-88.4846	42.93614	-2.06	0.0395	0	DV7	0

NUM16	-99.5487	49.31201	-2.02	0.0437	0	DV8	0
NUM17	-99.8797	42.78923	-2.33	0.0197	0	DV9	0
NUM18	-328.21	49.22219	-6.67	<.0001	0	DV10	0
NUM19	-117.22	45.78158	-2.56	0.0106	0	DV11	0
NUM20	-302.568	48.09252	-6.29	<.0001	0	DV12	0
NUM21	-623.441	49.46356	-12.6	<.0001	0	DV13	0
NUM22	-815.36	50.49416	-16.15	<.0001	0	DV14	0
NUM23	-730.009	50.53003	-14.45	<.0001	0	DV15	0
NUM24	-603.036	49.56135	-12.17	<.0001	0	DV16	0
NUM25	-515.972	48.04126	-10.74	<.0001	0	DV17	0
NUM26	-307.971	45.74794	-6.73	<.0001	0	DV18	0
NUM27	-332.73	49.30517	-6.75	<.0001	0	DV19	0
NUM28	-268.72	49.17081	-5.47	<.0001	0	DV20	0
NUM29	-224.822	49.40731	-4.55	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	3.75	1	0.053	-0.008	-0.014	-0.034	0.009	0.018	0.028
12	10.29	7	0.1728	-0.018	0	-0.04	0.027	0.027	0.033
18	14.21	13	0.3589	0.015	0.002	0.038	0.008	-0.021	-0.022
24	24.38	19	0.1819	-0.006	0.023	0.041	0.019	-0.057	0.031
30	30.29	25	0.2137	0.007	-0.003	0.004	0.019	-0.059	-0.008
36	35.62	31	0.2598	0.036	-0.007	0.01	0.002	0.045	-0.01
42	38.66	37	0.3946	-0.019	0.014	-0.006	-0.003	0.037	0.001
48	47.84	43	0.2827	-0.008	0.015	-0.002	0.074	0.012	-0.014

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.775433 Pr < W <.0001
Kolmogorov-Smirnov	D	0.107228 Pr > D <0.0100
Cramer-von Mises	W-Sq	6.613288 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	40.50104 Pr > A-Sq <0.0050

- Jam 18:00

The ARIMA Procedure  
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.35859	0.0266	13.48	<.0001	1	y	0
AR1,2	0.16224	0.02785	5.83	<.0001	2	y	0
AR1,3	0.10971	0.02673	4.1	<.0001	3	y	0
AR1,4	0.09685	0.02382	4.07	<.0001	7	y	0
AR1,5	0.08756	0.02264	3.87	0.0001	18	y	0
NUM1	0.42085	0.02905	14.49	<.0001	0	t	0
NUM2	3092.4	25.08146	123.29	<.0001	0	D1	0
NUM3	3097	25.04472	123.66	<.0001	0	D2	0

NUM4	3103	25.06594	123.79	<.0001	0	D3	0
NUM5	3099.4	25.10346	123.46	<.0001	0	D4	0
NUM6	3083.4	25.11444	122.77	<.0001	0	D5	0
NUM7	2994.9	25.09055	119.37	<.0001	0	D6	0
NUM8	2914.3	25.08302	116.19	<.0001	0	D7	0
NUM9	-291.246	43.13855	-6.75	<.0001	0	DV1	0
NUM10	-232.791	38.31226	-6.08	<.0001	0	DV2	0
NUM11	-262.395	49.16786	-5.34	<.0001	0	DV3	0
NUM12	-175.003	42.55498	-4.11	<.0001	0	DV4	0
NUM13	-223.841	42.86508	-5.22	<.0001	0	DV5	0
NUM14	-279.722	60.21593	-4.65	<.0001	0	DV6	0
NUM15	-88.4846	42.93614	-2.06	0.0395	0	DV7	0
NUM16	-99.5487	49.31201	-2.02	0.0437	0	DV8	0
NUM17	-99.8797	42.78923	-2.33	0.0197	0	DV9	0
NUM18	-328.21	49.22219	-6.67	<.0001	0	DV10	0
NUM19	-117.22	45.78158	-2.56	0.0106	0	DV11	0
NUM20	-302.568	48.09252	-6.29	<.0001	0	DV12	0
NUM21	-623.441	49.46356	-12.6	<.0001	0	DV13	0
NUM22	-815.36	50.49416	-16.15	<.0001	0	DV14	0
NUM23	-730.009	50.53003	-14.45	<.0001	0	DV15	0
NUM24	-603.036	49.56135	-12.17	<.0001	0	DV16	0
NUM25	-515.972	48.04126	-10.74	<.0001	0	DV17	0
NUM26	-307.971	45.74794	-6.73	<.0001	0	DV18	0
NUM27	-332.73	49.30517	-6.75	<.0001	0	DV19	0
NUM28	-268.72	49.17081	-5.47	<.0001	0	DV20	0
NUM29	-224.822	49.40731	-4.55	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.75	1	0.053	-0.008	-0.014	-0.034	0.009	0.018	0.028
12	10.29	7	0.1728	-0.018	0	-0.04	0.027	0.027	0.033
18	14.21	13	0.3589	0.015	0.002	0.038	0.008	-0.021	-0.022
24	24.38	19	0.1819	-0.006	0.023	0.041	0.019	-0.057	0.031
30	30.29	25	0.2137	0.007	-0.003	0.004	0.019	-0.059	-0.008
36	35.62	31	0.2598	0.036	-0.007	0.01	0.002	0.045	-0.01
42	38.66	37	0.3946	-0.019	0.014	-0.006	-0.003	0.037	0.001
48	47.84	43	0.2827	-0.008	0.015	-0.002	0.074	0.012	-0.014

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.775433 Pr < W <.00001
Kolmogorov-Smirnov	D	0.107228 Pr > D <0.0100
Cramer-von Mises	W-Sq	6.613288 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	40.50104 Pr > A-Sq <0.0050

- Jam 18:30

The ARIMA Procedure  
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.29368	0.02633	11.15	<.0001	1	y	0
AR1,2	0.15127	0.02712	5.58	<.0001	2	y	0
AR1,3	0.08133	0.02671	3.04	0.0024	3	y	0
AR1,4	0.07091	0.02519	2.81	0.005	7	y	0
AR1,5	0.09575	0.02489	3.85	0.0001	10	y	0
AR1,6	0.09061	0.02452	3.69	0.0002	18	y	0
AR1,7	0.05604	0.02424	2.31	0.0209	24	y	0
NUM1	0.47362	0.03417	13.86	<.0001	0	t	0
NUM2	3148.5	29.23029	107.71	<.0001	0	D1	0
NUM3	3151.5	29.1878	107.97	<.0001	0	D2	0
NUM4	3159.2	29.20595	108.17	<.0001	0	D3	0
NUM5	3155.4	29.24136	107.91	<.0001	0	D4	0
NUM6	3146.6	29.25663	107.55	<.0001	0	D5	0
NUM7	3061.8	29.22895	104.75	<.0001	0	D6	0
NUM8	2954.7	29.22386	101.11	<.0001	0	D7	0
NUM9	-346.557	47.19386	-7.34	<.0001	0	DV1	0
NUM10	-245.78	42.06324	-5.84	<.0001	0	DV2	0
NUM11	-282.635	54.1029	-5.22	<.0001	0	DV3	0
NUM12	-179.701	46.83603	-3.84	0.0001	0	DV4	0
NUM13	-239.31	47.21354	-5.07	<.0001	0	DV5	0
NUM14	-271.083	66.32315	-4.09	<.0001	0	DV6	0
NUM15	-91.1	47.28095	-1.93	0.0542	0	DV7	0
NUM16	-87.1579	54.26476	-1.61	0.1085	0	DV8	0
NUM17	-133.337	47.0736	-2.83	0.0047	0	DV9	0
NUM18	-389.188	54.15257	-7.19	<.0001	0	DV10	0
NUM19	-150.67	49.21447	-3.06	0.0022	0	DV11	0
NUM20	-372.392	50.97068	-7.31	<.0001	0	DV12	0
NUM21	-627.874	52.04104	-12.06	<.0001	0	DV13	0
NUM22	-856.681	52.61378	-16.28	<.0001	0	DV14	0
NUM23	-771.113	52.63985	-14.65	<.0001	0	DV15	0
NUM24	-611.421	52.09198	-11.74	<.0001	0	DV16	0
NUM25	-527.256	50.96732	-10.34	<.0001	0	DV17	0
NUM26	-318.271	49.23115	-6.46	<.0001	0	DV18	0
NUM27	-349.529	54.23492	-6.44	<.0001	0	DV19	0
NUM28	-252.189	54.15916	-4.66	<.0001	0	DV20	0
NUM29	-250.09	54.33403	-4.6	<.0001	0	DV21	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.011	-0.015	-0.036	0.033	0.031	0.042
12	9.07	5	0.1063	-0.011	0.009	0	-0.016	0.012	-0.01
18	13.93	11	0.2369	0.016	0.015	0.047	0.023	0.008	-0.009

24	19.2	17	0.3171	0.016	0.016	0.047	0.001	-0.029	0.002
30	19.6	23	0.6658	0.011	-0.009	0.002	0	-0.008	-0.004
36	29.35	29	0.4472	0.013	-0.021	0.003	0.014	0.069	-0.031
42	32.77	35	0.5764	-0.024	-0.018	0.007	0.015	0.032	0.007
48	38.9	41	0.5642	-0.02	0.021	0.025	0.047	0.014	0.015

Tests for Normality			
Test	---Statistic---	-----p Value-----	
Shapiro-Wilk	W	0.654286	Pr < W <0.0001
Kolmogorov-Smirnov	D	0.130198	Pr > D <0.0100
Cramer-von Mises	W-Sq	10.54726	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	63.821	Pr > A-Sq <0.0050

- Jam 19:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.28866	0.0264	10.93	<.0001	1	y	0
AR1,2	0.14864	0.02717	5.47	<.0001	2	y	0
AR1,3	0.08732	0.02649	3.3	0.001	3	y	0
AR1,4	0.09582	0.02472	3.88	0.0001	10	y	0
AR1,5	0.06613	0.02489	2.66	0.008	15	y	0
AR1,6	0.08359	0.02488	3.36	0.0008	18	y	0
NUM1	0.45335	0.02454	18.48	<.0001	0	t	0
NUM2	3176.6	21.36814	148.66	<.0001	0	D1	0
NUM3	3183.1	21.3371	149.18	<.0001	0	D2	0
NUM4	3189.7	21.35055	149.4	<.0001	0	D3	0
NUM5	3184.1	21.38669	148.88	<.0001	0	D4	0
NUM6	3173.5	21.39857	148.3	<.0001	0	D5	0
NUM7	3085.9	21.37028	144.4	<.0001	0	D6	0
NUM8	2984.2	21.36351	139.69	<.0001	0	D7	0
NUM9	-361.852	45.73019	-7.91	<.0001	0	DV1	0
NUM10	-247.301	40.88051	-6.05	<.0001	0	DV2	0
NUM11	-304.765	52.53692	-5.8	<.0001	0	DV3	0
NUM12	-178.148	45.48575	-3.92	<.0001	0	DV4	0
NUM13	-216.131	45.90701	-4.71	<.0001	0	DV5	0
NUM14	-272.863	64.40187	-4.24	<.0001	0	DV6	0
NUM15	-113.502	45.92445	-2.47	0.0136	0	DV7	0
NUM16	-100.006	52.72092	-1.9	0.058	0	DV8	0
NUM17	-143.436	45.7398	-3.14	0.0017	0	DV9	0
NUM18	-381.668	52.58426	-7.26	<.0001	0	DV10	0
NUM19	-164.629	47.74939	-3.45	0.0006	0	DV11	0
NUM20	-390.017	49.545	-7.87	<.0001	0	DV12	0
NUM21	-651.631	50.60077	-12.88	<.0001	0	DV13	0
NUM22	-875.3	51.18922	-17.1	<.0001	0	DV14	0
NUM23	-782.481	51.17791	-15.29	<.0001	0	DV15	0



NUM24	-622.357	50.55898	-12.31	<.0001	0	DV16	0
NUM25	-524.671	49.53205	-10.59	<.0001	0	DV17	0
NUM26	-322.978	47.73939	-6.77	<.0001	0	DV18	0
NUM27	-330.891	52.66058	-6.28	<.0001	0	DV19	0
NUM28	-250.536	52.59949	-4.76	<.0001	0	DV20	0
NUM29	-267.345	52.65052	-5.08	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.009	-0.017	-0.035	0.014	0.016	0.031
12	11.75	6	0.0679	0.053	0.041	0.011	-0.014	0.011	-0.003
18	12.7	12	0.3914	0.013	0.009	-0.005	-0.007	-0.003	-0.017
24	21.16	18	0.2712	0.014	0.012	0.042	0.021	-0.033	0.046
30	22.11	24	0.5729	0.01	-0.012	0.008	-0.007	-0.017	-0.002
36	31.5	30	0.3911	0.033	-0.006	0.006	0.016	0.067	-0.021
42	37.58	36	0.3965	-0.04	-0.02	0.015	0.018	0.033	0.019
48	43.38	42	0.4125	-0.018	0.014	0.017	0.051	0.015	0.013

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.680417 Pr < W
Kolmogorov-Smirnov	D	0.123708 Pr > D
Cramer-von Mises	W-Sq	9.127119 Pr > W-Sq
Anderson-Darling	A-Sq	55.89836 Pr > A-Sq

- Jam 20:00

The ARIMA Procedure  
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.30294	0.02658	11.4	<.0001	1	y	0
AR1,2	0.15602	0.02736	5.7	<.0001	2	y	0
AR1,3	0.09115	0.02687	3.39	0.0007	3	y	0
AR1,4	0.05529	0.02647	2.09	0.0369	6	y	0
AR1,5	0.07609	0.02612	2.91	0.0036	7	y	0
AR1,6	0.08379	0.02385	3.51	0.0005	18	y	0
AR1,7	0.06961	0.02341	2.97	0.003	46	y	0
NUM1	0.43162	0.03092	13.96	<.0001	0	t	0
NUM2	3141.4	26.50327	118.53	<.0001	0	D1	0
NUM3	3147.1	26.46428	118.92	<.0001	0	D2	0
NUM4	3150.4	26.48226	118.96	<.0001	0	D3	0
NUM5	3144.2	26.51886	118.57	<.0001	0	D4	0
NUM6	3132.1	26.52694	118.07	<.0001	0	D5	0
NUM7	3034.8	26.50596	114.49	<.0001	0	D6	0
NUM8	2951.7	26.49987	111.39	<.0001	0	D7	0
NUM9	-341.483	44.18369	-7.73	<.0001	0	DV1	0

NUM10	-241.515	39.27188	-6.15	<.0001	0	DV2	0
NUM11	-268.844	50.45285	-5.33	<.0001	0	DV3	0
NUM12	-179.906	43.655	-4.12	<.0001	0	DV4	0
NUM13	-231.631	43.9893	-5.27	<.0001	0	DV5	0
NUM14	-270.338	61.78005	-4.38	<.0001	0	DV6	0
NUM15	-121.458	44.07528	-2.76	0.0059	0	DV7	0
NUM16	-106.315	50.61953	-2.1	0.0359	0	DV8	0
NUM17	-131.766	43.90253	-3	0.0027	0	DV9	0
NUM18	-356.369	50.52141	-7.05	<.0001	0	DV10	0
NUM19	-140.91	46.10804	-3.06	0.0023	0	DV11	0
NUM20	-359.328	47.73028	-7.53	<.0001	0	DV12	0
NUM21	-624.261	48.65003	-12.83	<.0001	0	DV13	0
NUM22	-826.877	49.27362	-16.78	<.0001	0	DV14	0
NUM23	-745.847	49.25615	-15.14	<.0001	0	DV15	0
NUM24	-617.619	48.62655	-12.7	<.0001	0	DV16	0
NUM25	-519.132	47.66307	-10.89	<.0001	0	DV17	0
NUM26	-326.082	46.07654	-7.08	<.0001	0	DV18	0
NUM27	-324.285	50.55582	-6.41	<.0001	0	DV19	0
NUM28	-263.924	50.54979	-5.22	<.0001	0	DV20	0
NUM29	-246.619	50.59916	-4.87	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.005	-0.012	-0.025	0.025	0.023	-0.011
12	10.04	5	0.0741	-0.018	0.01	-0.026	0.036	0.038	0.03
18	14.37	11	0.213	0.009	-0.004	0.046	0.013	-0.012	-0.021
24	26.78	17	0.0614	-0.004	0.031	0.063	0.021	-0.041	0.036
30	28.67	23	0.1915	0.009	-0.009	0.004	0.016	-0.029	0.004
36	35.53	29	0.1878	0.038	0.004	0.013	0.007	0.054	-0.007
42	38.43	35	0.3171	-0.022	0.013	-0.015	0	0.031	0.008
48	40.39	41	0.4974	-0.011	0.021	0.006	0.024	-0.008	-0.009

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.739144 Pr < W
Kolmogorov-Smirnov	D	0.132981 Pr > D
Cramer-von Mises	W-Sq	8.531092 Pr > W-Sq
Anderson-Darling	A-Sq	50.62949 Pr > A-Sq

- Jam 20:30

The ARIMA Procedure  
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.35859	0.0266	13.48	<.0001	1	y	0
AR1,2	0.16224	0.02785	5.83	<.0001	2	y	0

AR1,3	0.10971	0.02673	4.1	<.0001	3	y	0
AR1,4	0.09685	0.02382	4.07	<.0001	7	y	0
AR1,5	0.08756	0.02264	3.87	0.0001	18	y	0
NUM1	0.42085	0.02905	14.49	<.0001	0	t	0
NUM2	3092.4	25.08146	123.29	<.0001	0	D1	0
NUM3	3097	25.04472	123.66	<.0001	0	D2	0
NUM4	3103	25.06594	123.79	<.0001	0	D3	0
NUM5	3099.4	25.10346	123.46	<.0001	0	D4	0
NUM6	3083.4	25.11444	122.77	<.0001	0	D5	0
NUM7	2994.9	25.09055	119.37	<.0001	0	D6	0
NUM8	2914.3	25.08302	116.19	<.0001	0	D7	0
NUM9	-291.246	43.13855	-6.75	<.0001	0	DV1	0
NUM10	-232.791	38.31226	-6.08	<.0001	0	DV2	0
NUM11	-262.395	49.16786	-5.34	<.0001	0	DV3	0
NUM12	-175.003	42.55498	-4.11	<.0001	0	DV4	0
NUM13	-223.841	42.86508	-5.22	<.0001	0	DV5	0
NUM14	-279.722	60.21593	-4.65	<.0001	0	DV6	0
NUM15	-88.4846	42.93614	-2.06	0.0395	0	DV7	0
NUM16	-99.5487	49.31201	-2.02	0.0437	0	DV8	0
NUM17	-99.8797	42.78923	-2.33	0.0197	0	DV9	0
NUM18	-328.21	49.22219	-6.67	<.0001	0	DV10	0
NUM19	-117.22	45.78158	-2.56	0.0106	0	DV11	0
NUM20	-302.568	48.09252	-6.29	<.0001	0	DV12	0
NUM21	-623.441	49.46356	-12.6	<.0001	0	DV13	0
NUM22	-815.36	50.49416	-16.15	<.0001	0	DV14	0
NUM23	-730.009	50.53003	-14.45	<.0001	0	DV15	0
NUM24	-603.036	49.56135	-12.17	<.0001	0	DV16	0
NUM25	-515.972	48.04126	-10.74	<.0001	0	DV17	0
NUM26	-307.971	45.74794	-6.73	<.0001	0	DV18	0
NUM27	-332.73	49.30517	-6.75	<.0001	0	DV19	0
NUM28	-268.72	49.17081	-5.47	<.0001	0	DV20	0
NUM29	-224.822	49.40731	-4.55	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To	Chi-	DF	Pr >	-----Autocorrelations-----					
Lag	Square		ChiSq						
6	3.75	1	0.053	-0.008	-0.014	-0.034	0.009	0.018	0.028
12	10.29	7	0.1728	-0.018	0	-0.04	0.027	0.027	0.033
18	14.21	13	0.3589	0.015	0.002	0.038	0.008	-0.021	-0.022
24	24.38	19	0.1819	-0.006	0.023	0.041	0.019	-0.057	0.031
30	30.29	25	0.2137	0.007	-0.003	0.004	0.019	-0.059	-0.008
36	35.62	31	0.2598	0.036	-0.007	0.01	0.002	0.045	-0.01
42	38.66	37	0.3946	-0.019	0.014	-0.006	-0.003	0.037	0.001
48	47.84	43	0.2827	-0.008	0.015	-0.002	0.074	0.012	-0.014

Test	Tests for Normality			
	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.775433	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.107228	Pr > D	<0.0100
Cramer-von Mises	W-Sq	6.613288	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	40.50104	Pr > A-Sq	<0.0050

- Jam 21:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.3732	0.02656	14.05	<.0001	1	y	0
AR1,2	0.18407	0.02788	6.6	<.0001	2	y	0
AR1,3	0.12647	0.02695	4.69	<.0001	3	y	0
AR1,4	0.0829	0.02354	3.52	0.0004	7	y	0
AR1,5	0.07597	0.02163	3.51	0.0005	18	y	0
NUM1	0.41054	0.03287	12.49	<.0001	0	t	0
NUM2	2985.9	28.11078	106.22	<.0001	0	D1	0
NUM3	2988.6	28.06935	106.47	<.0001	0	D2	0
NUM4	2995.5	28.0928	106.63	<.0001	0	D3	0
NUM5	3003.2	28.1307	106.76	<.0001	0	D4	0
NUM6	2978.2	28.1428	105.83	<.0001	0	D5	0
NUM7	2903.7	28.12011	103.26	<.0001	0	D6	0
NUM8	2819.4	28.11255	100.29	<.0001	0	D7	0
NUM9	-280.689	41.75094	-6.72	<.0001	0	DV1	0
NUM10	-232.035	37.03409	-6.27	<.0001	0	DV2	0
NUM11	-273.471	47.57294	-5.75	<.0001	0	DV3	0
NUM12	-163.638	41.16888	-3.97	<.0001	0	DV4	0
NUM13	-214.551	41.47735	-5.17	<.0001	0	DV5	0
NUM14	-279.189	58.28004	-4.79	<.0001	0	DV6	0
NUM15	-98.4553	41.57331	-2.37	0.018	0	DV7	0
NUM16	-100.734	47.67378	-2.11	0.0348	0	DV8	0
NUM17	-111.975	41.41875	-2.7	0.0069	0	DV9	0
NUM18	-314.59	47.63469	-6.6	<.0001	0	DV10	0
NUM19	-86.7401	44.65826	-1.94	0.0523	0	DV11	0
NUM20	-259.658	47.08625	-5.51	<.0001	0	DV12	0
NUM21	-572.367	48.71993	-11.75	<.0001	0	DV13	0
NUM22	-776.201	49.96955	-15.53	<.0001	0	DV14	0
NUM23	-692.013	49.9927	-13.84	<.0001	0	DV15	0
NUM24	-582.992	48.80101	-11.95	<.0001	0	DV16	0
NUM25	-492.948	47.03811	-10.48	<.0001	0	DV17	0
NUM26	-295.074	44.6169	-6.61	<.0001	0	DV18	0
NUM27	-360.809	47.70644	-7.56	<.0001	0	DV19	0
NUM28	-237.398	47.5938	-4.99	<.0001	0	DV20	0
NUM29	-229.123	47.7561	-4.8	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.79	1	0.0161	-0.009	-0.013	-0.035	0.027	0.001	0.042
12	12.87	7	0.0753	-0.016	0.017	-0.036	0.009	0.012	0.052
18	14.58	13	0.3344	-0.003	-0.002	0.031	-0.002	-0.004	-0.013
24	21.06	19	0.3333	-0.004	-0.001	0.047	0.011	-0.044	0.008
30	28.89	25	0.2686	0.004	-0.008	-0.001	0.022	-0.067	-0.014
36	31.16	31	0.4583	0.029	-0.003	-0.004	0.015	0.014	-0.016
42	34.83	37	0.5713	-0.021	0.03	0.004	0.011	0.013	0.027
48	46.1	43	0.3451	-0.015	0.009	-0.016	0.08	0.016	-0.014

## Tests for Normality

Test	---Statistic---	-----p Value-----	
Shapiro-Wilk	W	0.818727	Pr < W <0.0001
Kolmogorov-Smirnov	D	0.099087	Pr > D <0.0100
Cramer-von Mises	W-Sq	5.164401	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	31.08136	Pr > A-Sq <0.0050

- Jam 21:30

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.42024	0.02663	15.78	<.0001	1	y	0
AR1,2	0.17115	0.02874	5.95	<.0001	2	y	0
AR1,3	0.11792	0.02869	4.11	<.0001	3	y	0
AR1,4	0.07512	0.02663	2.82	0.0049	4	y	0
AR1,5	0.07624	0.02007	3.8	0.0002	18	y	0
NUM1	0.39737	0.03409	11.66	<.0001	0	t	0
NUM2	2849.9	28.92886	98.52	<.0001	0	D1	0
NUM3	2852.7	28.88518	98.76	<.0001	0	D2	0
NUM4	2857.1	28.90984	98.83	<.0001	0	D3	0
NUM5	2878.3	28.93964	99.46	<.0001	0	D4	0
NUM6	2838.7	28.9464	98.07	<.0001	0	D5	0
NUM7	2780.7	28.93214	96.11	<.0001	0	D6	0
NUM8	2685.3	28.9299	92.82	<.0001	0	D7	0
NUM9	-274.677	38.05109	-7.22	<.0001	0	DV1	0
NUM10	-245.156	33.85091	-7.24	<.0001	0	DV2	0
NUM11	-277.177	43.50728	-6.37	<.0001	0	DV3	0
NUM12	-163.713	37.64295	-4.35	<.0001	0	DV4	0
NUM13	-195.759	37.97793	-5.15	<.0001	0	DV5	0
NUM14	-256.966	53.27987	-4.82	<.0001	0	DV6	0
NUM15	-108.152	38.00942	-2.85	0.0045	0	DV7	0
NUM16	-90.3585	43.60182	-2.07	0.0384	0	DV8	0
NUM17	-114.262	37.84729	-3.02	0.0026	0	DV9	0
NUM18	-296.439	43.53643	-6.81	<.0001	0	DV10	0

NUM19	-48.0682	41.33256	-1.16	0.245	0	DV11	0
NUM20	-226.925	44.35577	-5.12	<.0001	0	DV12	0
NUM21	-472.467	45.84774	-10.31	<.0001	0	DV13	0
NUM22	-740.618	46.70243	-15.86	<.0001	0	DV14	0
NUM23	-638.627	46.67112	-13.68	<.0001	0	DV15	0
NUM24	-535.16	45.79473	-11.69	<.0001	0	DV16	0
NUM25	-480.095	44.24273	-10.85	<.0001	0	DV17	0
NUM26	-276.044	41.25077	-6.69	<.0001	0	DV18	0
NUM27	-359.398	43.62751	-8.24	<.0001	0	DV19	0
NUM28	-238.689	43.50794	-5.49	<.0001	0	DV20	0
NUM29	-217.254	43.57992	-4.99	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.01	1	0.1558	-0.003	-0.008	-0.016	-0.03	0.007	0.009
12	8.32	7	0.3049	0.022	0.028	-0.015	0.008	0.032	0.042
18	10.93	13	0.6168	-0.008	-0.007	0.039	-0.005	-0.009	-0.002
24	14.59	19	0.748	0.002	0.003	0.036	-0.001	-0.033	0.008
30	22.52	25	0.6054	-0.005	-0.008	-0.018	0.015	-0.055	-0.041
36	25.56	31	0.7421	0.033	0.023	-0.014	0.004	-0.005	-0.014
42	31.43	37	0.7271	-0.027	0.022	0.02	0.038	-0.016	0.025
48	43.7	43	0.4417	-0.016	0	-0.028	0.084	0	-0.007

Tests for Normality			
Test	---Statistic---	-----p Value-----	
Shapiro-Wilk	W	0.861779	Pr < W <.0001
Kolmogorov-Smirnov	D	0.090973	Pr > D <.0100
Cramer-von Mises	W-Sq	3.684381	Pr > W-Sq <.0050
Anderson-Darling	A-Sq	22.61529	Pr > A-Sq <.0050

• Jam 22:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.44709	0.02663	16.79	<.0001	1	y	0
AR1,2	0.16852	0.02905	5.8	<.0001	2	y	0
AR1,3	0.12002	0.0289	4.15	<.0001	3	y	0
AR1,4	0.08766	0.02664	3.29	0.001	4	y	0
AR1,5	0.04763	0.01881	2.53	0.0114	46	y	0
NUM1	0.38748	0.03374	11.48	<.0001	0	t	0
NUM2	2703.5	28.57972	94.6	<.0001	0	D1	0
NUM3	2708.2	28.5357	94.9	<.0001	0	D2	0
NUM4	2712	28.56104	94.96	<.0001	0	D3	0
NUM5	2736.1	28.58902	95.7	<.0001	0	D4	0
NUM6	2700.6	28.59707	94.43	<.0001	0	D5	0

NUM7	2643.3	28.58492	92.47	<.0001	0	D6	0
NUM8	2550.5	28.58344	89.23	<.0001	0	D7	0
NUM9	-255.585	35.34813	-7.23	<.0001	0	DV1	0
NUM10	-233.89	31.46847	-7.43	<.0001	0	DV2	0
NUM11	-266.567	40.42406	-6.59	<.0001	0	DV3	0
NUM12	-162.035	34.97323	-4.63	<.0001	0	DV4	0
NUM13	-188.559	35.30201	-5.34	<.0001	0	DV5	0
NUM14	-261.211	49.51475	-5.28	<.0001	0	DV6	0
NUM15	-107.064	35.3509	-3.03	0.0025	0	DV7	0
NUM16	-97.6089	40.50599	-2.41	0.0161	0	DV8	0
NUM17	-105.137	35.18836	-2.99	0.0029	0	DV9	0
NUM18	-263.133	40.45498	-6.5	<.0001	0	DV10	0
NUM19	-43.3081	38.68295	-1.12	0.2631	0	DV11	0
NUM20	-202.045	41.78847	-4.83	<.0001	0	DV12	0
NUM21	-373.326	43.25299	-8.63	<.0001	0	DV13	0
NUM22	-713.751	44.04812	-16.2	<.0001	0	DV14	0
NUM23	-621.161	43.9935	-14.12	<.0001	0	DV15	0
NUM24	-512.364	43.15597	-11.87	<.0001	0	DV16	0
NUM25	-449.121	41.69426	-10.77	<.0001	0	DV17	0
NUM26	-280.672	38.61351	-7.27	<.0001	0	DV18	0
NUM27	-343.445	40.53837	-8.47	<.0001	0	DV19	0
NUM28	-212.022	40.40916	-5.25	<.0001	0	DV20	0
NUM29	-206.515	40.51342	-5.1	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.47	1	0.2255	0.002	-0.004	-0.013	-0.027	-0.001	-0.009
12	10.13	7	0.1814	0.018	0.018	-0.049	0.023	0.013	0.046
18	17.98	13	0.1583	-0.005	0.009	0.025	-0.022	0.004	0.064
24	27.65	19	0.0903	0.033	0.033	0.056	0.017	-0.015	0.026
30	33.75	25	0.1133	-0.005	0.009	-0.021	0.014	-0.054	-0.02
36	36.66	31	0.2227	0.016	0.029	-0.01	0.023	0.007	-0.013
42	42.78	37	0.2368	-0.032	0.032	0.016	0.022	0.006	0.036
48	51.9	43	0.1656	0.002	-0.005	-0.019	0.055	-0.046	-0.022

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.907052 Pr < W <0.0001
Kolmogorov-Smirnov	D	0.071549 Pr > D <0.0100
Cramer-von Mises	W-Sq	2.389944 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	15.05528 Pr > A-Sq <0.0050

• Jam 22:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.49557	0.02664	18.6	<.0001	1	y	0
AR1,2	0.15586	0.02979	5.23	<.0001	2	y	0
AR1,3	0.08982	0.02985	3.01	0.0027	3	y	0
AR1,4	0.06679	0.02791	2.39	0.0169	4	y	0
AR1,5	0.05143	0.02259	2.28	0.023	7	y	0
NUM1	0.38371	0.02979	12.88	<.0001	0	t	0
NUM2	2594.3	25.28237	102.61	<.0001	0	D1	0
NUM3	2595.4	25.2422	102.82	<.0001	0	D2	0
NUM4	2601.9	25.27019	102.96	<.0001	0	D3	0
NUM5	2619.9	25.2993	103.56	<.0001	0	D4	0
NUM6	2590.6	25.311	102.35	<.0001	0	D5	0
NUM7	2536.9	25.29624	100.29	<.0001	0	D6	0
NUM8	2438.5	25.29008	96.42	<.0001	0	D7	0
NUM9	-246.965	32.11708	-7.69	<.0001	0	DV1	0
NUM10	-227.045	28.59431	-7.94	<.0001	0	DV2	0
NUM11	-255.488	36.69352	-6.96	<.0001	0	DV3	0
NUM12	-163.861	31.75257	-5.16	<.0001	0	DV4	0
NUM13	-177.931	32.0225	-5.56	<.0001	0	DV5	0
NUM14	-245.556	44.92005	-5.47	<.0001	0	DV6	0
NUM15	-100.32	32.10067	-3.13	0.0018	0	DV7	0
NUM16	-111.434	36.75499	-3.03	0.0025	0	DV8	0
NUM17	-101.072	31.98234	-3.16	0.0016	0	DV9	0
NUM18	-253.371	36.72824	-6.9	<.0001	0	DV10	0
NUM19	-33.3395	35.49143	-0.94	0.3477	0	DV11	0
NUM20	-197.234	38.91623	-5.07	<.0001	0	DV12	0
NUM21	-316.526	40.59122	-7.8	<.0001	0	DV13	0
NUM22	-719.294	41.34629	-17.4	<.0001	0	DV14	0
NUM23	-632.164	41.30182	-15.31	<.0001	0	DV15	0
NUM24	-522.243	40.5085	-12.89	<.0001	0	DV16	0
NUM25	-452.924	38.80572	-11.67	<.0001	0	DV17	0
NUM26	-251.38	35.42033	-7.1	<.0001	0	DV18	0
NUM27	-335.182	36.78109	-9.11	<.0001	0	DV19	0
NUM28	-235.151	36.69068	-6.41	<.0001	0	DV20	0
NUM29	-201.486	36.80868	-5.47	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.05	1	0.3055	-0.002	-0.001	-0.006	-0.013	0.019	-0.012
12	10.37	7	0.1684	-0.014	-0.012	-0.065	0.003	0.006	0.042
18	17.47	13	0.1787	-0.021	0.005	0.001	0.004	0.002	0.066
24	23.25	19	0.2265	0.014	0.012	0.038	0.027	-0.007	0.036
30	29.04	25	0.2624	-0.016	0.008	-0.016	0.024	-0.048	-0.02



36	32.95	31	0.3718	0.013	0.028	-0.035	0.01	0.015	-0.012
42	38.39	37	0.4062	-0.007	0.018	0.043	0.009	-0.001	0.037
48	57.71	43	0.0662	-0.019	0.04	-0.018	0.088	-0.052	0.001

Test	Tests for Normality			
	---Statistic---	-----p Value-----		
Shapiro-Wilk	W	0.924302	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.06963	Pr > D	<0.0100
Cramer-von Mises	W-Sq	2.176063	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	13.89184	Pr > A-Sq	<0.0050

- Jam 23:00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.53639	0.02655	20.2	<.0001	1	y	0
AR1,2	0.1533	0.03009	5.09	<.0001	2	y	0
AR1,3	0.11033	0.02757	4	<.0001	3	y	0
AR1,4	0.07087	0.02098	3.38	0.0007	7	y	0
NUM1	0.37862	0.02986	12.68	<.0001	0	t	0
NUM2	2489.1	25.24358	98.6	<.0001	0	D1	0
NUM3	2491.4	25.20303	98.85	<.0001	0	D2	0
NUM4	2496.6	25.23339	98.94	<.0001	0	D3	0
NUM5	2510.4	25.26391	99.37	<.0001	0	D4	0
NUM6	2488.6	25.2801	98.44	<.0001	0	D5	0
NUM7	2439.4	25.26244	96.56	<.0001	0	D6	0
NUM8	2344.7	25.25447	92.84	<.0001	0	D7	0
NUM9	-232.248	29.40183	-7.9	<.0001	0	DV1	0
NUM10	-202.718	26.09594	-7.77	<.0001	0	DV2	0
NUM11	-252.271	33.44053	-7.54	<.0001	0	DV3	0
NUM12	-168.848	28.97508	-5.83	<.0001	0	DV4	0
NUM13	-159.955	29.19822	-5.48	<.0001	0	DV5	0
NUM14	-250.459	40.95876	-6.11	<.0001	0	DV6	0
NUM15	-85.9405	29.27503	-2.94	0.0034	0	DV7	0
NUM16	-106.069	33.53881	-3.16	0.0016	0	DV8	0
NUM17	-105.628	29.16829	-3.62	0.0003	0	DV9	0
NUM18	-232.952	33.45927	-6.96	<.0001	0	DV10	0
NUM19	-50.2565	32.86438	-1.53	0.1264	0	DV11	0
NUM20	-208.804	36.59047	-5.71	<.0001	0	DV12	0
NUM21	-278.251	38.49743	-7.23	<.0001	0	DV13	0
NUM22	-688.321	39.73665	-17.32	<.0001	0	DV14	0
NUM23	-613.605	39.72447	-15.45	<.0001	0	DV15	0
NUM24	-511.772	38.4642	-13.31	<.0001	0	DV16	0
NUM25	-431.659	36.50434	-11.82	<.0001	0	DV17	0
NUM26	-226.849	32.81916	-6.91	<.0001	0	DV18	0
NUM27	-308.897	33.53171	-9.21	<.0001	0	DV19	0

NUM28	-220.362	33.49795	-6.58	<.0001	0	DV20	0
NUM29	-192.331	33.61794	-5.72	<.0001	0	DV21	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.63	2	0.1626	-0.004	-0.01	-0.033	0.013	0.033	0
12	14.41	8	0.0717	-0.006	-0.034	-0.068	0.007	0.019	0.034
18	16.74	14	0.2702	-0.014	0.007	0.009	0	0	0.035
24	23.39	20	0.2702	0.037	0.009	0.037	0.033	-0.013	0.02
30	27.79	26	0.3691	-0.023	0.004	-0.018	0.021	-0.04	-0.005
36	35.78	32	0.2955	0.021	0.021	-0.02	-0.004	0.057	-0.028
42	39.57	38	0.3996	-0.011	0.013	0.038	0.014	-0.006	0.023
48	56.47	44	0.0984	-0.011	0.041	-0.007	0.081	-0.049	-0.018

Tests for Normality			
Test	---Statistic---	-----p Value-----	
Shapiro-Wilk	W	0.941248	Pr < W <0.0001
Kolmogorov-Smirnov	D	0.058436	Pr > D <0.0100
Cramer-von Mises	W-Sq	1.756692	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	11.38726	Pr > A-Sq <0.0050

• Jam 23:30

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.60699	0.02655	22.86	<.0001	1	y	0
AR1,2	0.10383	0.03124	3.32	0.0009	2	y	0
AR1,3	0.08552	0.02754	3.11	0.0019	3	y	0
AR1,4	0.08891	0.02018	4.41	<.0001	7	y	0
NUM1	0.3725	0.03061	12.17	<.0001	0	t	0
NUM2	2415.5	25.74533	93.82	<.0001	0	D1	0
NUM3	2417.4	25.70289	94.05	<.0001	0	D2	0
NUM4	2421	25.74066	94.05	<.0001	0	D3	0
NUM5	2434.2	25.77243	94.45	<.0001	0	D4	0
NUM6	2415.9	25.78926	93.68	<.0001	0	D5	0
NUM7	2364.1	25.77283	91.73	<.0001	0	D6	0
NUM8	2271.6	25.76354	88.17	<.0001	0	D7	0
NUM9	-235.657	26.50894	-8.89	<.0001	0	DV1	0
NUM10	-195.202	23.56231	-8.28	<.0001	0	DV2	0
NUM11	-239.72	30.15175	-7.95	<.0001	0	DV3	0
NUM12	-150.295	26.14832	-5.75	<.0001	0	DV4	0
NUM13	-159.21	26.32035	-6.05	<.0001	0	DV5	0
NUM14	-246.577	36.92927	-6.68	<.0001	0	DV6	0
NUM15	-76.6001	26.37092	-2.9	0.0037	0	DV7	0
NUM16	-112.581	30.2355	-3.72	0.0002	0	DV8	0

NUM17	-94.0388	26.29475	-3.58	0.0004	0	DV9	0
NUM18	-268.863	30.1969	-8.9	<.0001	0	DV10	0
NUM19	-43.6952	30.29648	-1.44	0.1495	0	DV11	0
NUM20	-205.544	34.69613	-5.92	<.0001	0	DV12	0
NUM21	-290.795	36.67293	-7.93	<.0001	0	DV13	0
NUM22	-678.26	37.8018	-17.94	<.0001	0	DV14	0
NUM23	-620.211	37.8087	-16.4	<.0001	0	DV15	0
NUM24	-503.452	36.6953	-13.72	<.0001	0	DV16	0
NUM25	-437.91	34.6266	-12.65	<.0001	0	DV17	0
NUM26	-204.191	30.24816	-6.75	<.0001	0	DV18	0
NUM27	-292.309	30.32204	-9.64	<.0001	0	DV19	0
NUM28	-214.433	30.20481	-7.1	<.0001	0	DV20	0
NUM29	-200.992	30.366	-6.62	<.0001	0	DV21	0

## Autocorrelation Check of Residuals

To	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
Lag									
6	5.07	2	0.0791	0	-0.006	-0.03	0.007	0.048	-0.012
12	14	8	0.0819	0.013	-0.044	-0.056	-0.013	0.014	0.022
18	18.74	14	0.1753	-0.024	-0.011	0.034	-0.017	0.004	0.032
24	25.63	20	0.1784	0.051	-0.006	0.016	0.032	0.006	0.027
30	29.95	26	0.2698	-0.027	-0.001	-0.009	0.028	-0.023	-0.027
36	36.62	32	0.2628	0.019	0.034	-0.027	-0.013	0.04	-0.02
42	41.77	38	0.3102	0	0.009	0.055	-0.006	-0.003	0.017
48	57.5	44	0.0834	-0.015	0.061	-0.006	0.069	-0.038	-0.012

## Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.954292 Pr < W <.0001
Kolmogorov-Smirnov	D	0.058025 Pr > D <.0100
Cramer-von Mises	W-Sq	1.629023 Pr > W-Sq <.00050
Anderson-Darling	A-Sq	39984.5 Pr > A-Sq <.00050

- Jam 24:00

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.59483	0.02633	22.59	<.0001	1	y	0
AR1,2	0.13874	0.02775	5	<.0001	2	y	0
AR1,3	0.08015	0.02462	3.26	0.0012	5	y	0
AR1,4	0.07326	0.02287	3.2	0.0014	7	y	0
NUM1	0.36457	0.03052	11.95	<.0001	0	t	0
NUM2	2343.9	25.65894	91.35	<.0001	0	D1	0
NUM3	2349.2	25.61631	91.71	<.0001	0	D2	0
NUM4	2353.6	25.65365	91.74	<.0001	0	D3	0
NUM5	2366.3	25.68954	92.11	<.0001	0	D4	0

NUM6	2349.4	25.70721	91.39	<.0001	0	D5	0
NUM7	2296.3	25.68999	89.38	<.0001	0	D6	0
NUM8	2214.1	25.67753	86.23	<.0001	0	D7	0
NUM9	-235.697	26.12331	-9.02	<.0001	0	DV1	0
NUM10	-189.589	23.31708	-8.13	<.0001	0	DV2	0
NUM11	-287.308	29.87763	-9.62	<.0001	0	DV3	0
NUM12	-156.523	25.89672	-6.04	<.0001	0	DV4	0
NUM13	-166.079	26.06016	-6.37	<.0001	0	DV5	0
NUM14	-257.322	36.5749	-7.04	<.0001	0	DV6	0
NUM15	-81.3473	26.23098	-3.1	0.002	0	DV7	0
NUM16	-92.7827	29.92088	-3.1	0.002	0	DV8	0
NUM17	-84.9367	26.16099	-3.25	0.0012	0	DV9	0
NUM18	-274.006	29.90459	-9.16	<.0001	0	DV10	0
NUM19	-45.0275	29.79997	-1.51	0.131	0	DV11	0
NUM20	-209.622	33.85528	-6.19	<.0001	0	DV12	0
NUM21	-335.941	36.01392	-9.33	<.0001	0	DV13	0
NUM22	-668.158	36.60646	-18.25	<.0001	0	DV14	0
NUM23	-636.03	36.632	-17.36	<.0001	0	DV15	0
NUM24	-518.74	36.00678	-14.41	<.0001	0	DV16	0
NUM25	-462.807	33.86218	-13.67	<.0001	0	DV17	0
NUM26	-212.79	29.80412	-7.14	<.0001	0	DV18	0
NUM27	-289.646	29.97953	-9.66	<.0001	0	DV19	0
NUM28	-203.15	30.03149	-6.76	<.0001	0	DV20	0
NUM29	-147.631	30.03301	-4.92	<.0001	0	DV21	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.08	2	0.0477	-0.003	-0.032	0.021	0.038	0.009	-0.034
12	12.54	8	0.1288	0.002	-0.03	-0.056	0.007	0.015	-0.011
18	16.41	14	0.2892	-0.005	0.017	0.016	-0.003	-0.01	0.044
24	25.48	20	0.1838	0.045	-0.029	0.039	0.011	-0.001	0.04
30	31.42	26	0.213	-0.023	-0.028	-0.002	0.034	-0.035	-0.018
36	41.04	32	0.1313	0.038	0.02	-0.026	-0.034	0.052	-0.004
42	45.45	38	0.1895	-0.003	0.02	0.031	0.014	-0.02	0.031
48	52.79	44	0.1708	-0.003	0.036	-0.008	0.053	-0.025	-0.011

Tests for Normality

Test	---Statistic---	-----p Value-----
Shapiro-Wilk	W	0.965697 Pr < W <0.0001
Kolmogorov-Smirnov	D	0.0531 Pr > D <0.0100
Cramer-von Mises	W-Sq	1.448858 Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	8.895361 Pr > A-Sq <0.0050

**Lampiran 9** Jumlah Otlir untuk masing-masing Waktu

<b>Jam</b>	<b>Jumlah Outlier</b>	<b>Jam</b>	<b>Jumlah Outlier</b>	<b>Jam</b>	<b>Jumlah Outlier</b>
00:30	113	08:30	60	16:30	79
01:00	113	09:00	55	17:00	116
01:30	145	09:30	62	17:30	169
02:00	116	10:00	69	18:00	58
02:30	62	10:30	80	18:30	106
03:00	71	11:00	86	19:00	135
03:30	58	11:30	99	19:30	124
04:00	52	12:00	106	20:00	60
04:30	68	12:30	75	20:30	125
05:00	66	13:00	109	21:00	188
05:30	79	13:30	77	21:30	66
06:00	31	14:00	80	22:00	97
06:30	63	14:30	79	22:30	85
07:00	56	15:00	59	23:00	118
07:30	71	15:30	66	23:30	224
08:00	45	16:00	70	00:00	122

**Lampiran 10 Uji White Data Beban Listrik Jateng-DIY**

Jam	F	df1	df2	p-value	Ket	Jam	F	df1	df2	p-value	Ket
<b>00:30</b>	1.3840	2	1359	0.2509	Linear	<b>01:00</b>	4.3417	2	1360	0.0132	Linear
	0.2812	2	1359	0.7549			0.5069	2	1360	0.6025	
	0.1508	2	1359	0.8600			1.2464	2	1360	0.2879	
	1.0894	2	1359	0.3367			0.7215	2	1360	0.4862	
	0.0798	2	1359	0.9233			0.6843	2	1360	0.5046	
	2.3462	2	1359	0.0961			1.3338	2	1360	0.2638	
	0.4869	2	1359	0.6146			2.3731	2	1360	0.0936	
	0.6789	2	1359	0.5074			0.1291	2	1360	0.8789	
	2.5171	2	1359	0.0811			0.5240	2	1360	0.5923	
	6.4895	2	1359	0.0016			2.1972	2	1360	0.1115	
<b>01:30</b>	0.2618	2	1359	0.7697	Linear	<b>02:00</b>	0.4896	2	1359	0.6130	Linear
	0.2362	2	1359	0.7897			1.2002	2	1359	0.3014	
	0.6258	2	1359	0.5350			1.2668	2	1359	0.2821	
	2.2707	2	1359	0.1036			0.4827	2	1359	0.6172	
	0.0823	2	1359	0.9210			1.8978	2	1359	0.1503	
	0.4274	2	1359	0.6523			0.0277	2	1359	0.9727	
	0.7794	2	1359	0.4589			2.9891	2	1359	0.0507	
	1.0718	2	1359	0.3427			0.8631	2	1359	0.4221	
	0.3653	2	1359	0.6940			1.8983	2	1359	0.1502	
	0.7454	2	1359	0.4747			1.5162	2	1359	0.2199	
<b>02:30</b>	0.0843	2	1362	0.9191	Linear	<b>03:00</b>	1.7808	2	1364	0.1689	Linear
	0.1391	2	1362	0.8702			0.0926	2	1364	0.9116	
	2.5279	2	1362	0.0802			0.0714	2	1364	0.9311	
	0.7164	2	1362	0.4887			0.5760	2	1364	0.5623	
	0.8578	2	1362	0.4243			0.6284	2	1364	0.5336	
	0.9323	2	1362	0.3939			1.7573	2	1364	0.1729	
	0.2024	2	1362	0.8168			1.7363	2	1364	0.1766	
	0.9271	2	1362	0.3959			2.1816	2	1364	0.1133	
	0.0472	2	1362	0.9539			0.0411	2	1364	0.9598	
	2.0895	2	1362	0.1241			1.1964	2	1364	0.3026	
<b>03:30</b>	0.3815	2	1365	0.6829	Linear	<b>04:00</b>	0.0047	2	1364	0.9953	Linear
	1.2656	2	1365	0.2824			0.5870	2	1364	0.5561	
	2.8538	2	1365	0.0580			0.4088	2	1364	0.6645	
	3.3056	2	1365	0.0370			1.0383	2	1364	0.3543	
	0.7254	2	1365	0.4843			0.2411	2	1364	0.7858	
	0.9007	2	1365	0.4065			0.0071	2	1364	0.9929	
	0.1512	2	1365	0.8597			0.5117	2	1364	0.5996	
	0.4623	2	1365	0.6299			0.4022	2	1364	0.6689	
	1.6218	2	1365	0.1979			0.1844	2	1364	0.8316	
	0.5840	2	1365	0.5578			2.1460	2	1364	0.1174	

Jam	F	df1	df2	p-value	Ket	Jam	F	df1	df2	p-value	Ket
04:30	0.5764	2	1362	0.5621	Linear	05:00	3.3633	2	1363	0.0349	Linear
	1.9558	2	1362	0.1418			1.7597	2	1363	0.1725	
	1.5037	2	1362	0.2227			0.4353	2	1363	0.6472	
	0.3165	2	1362	0.7287			1.3186	2	1363	0.2679	
	2.7714	2	1362	0.0629			0.7015	2	1363	0.4960	
	5.3635	2	1362	0.0048			0.6864	2	1363	0.5036	
	1.0790	2	1362	0.3402			2.6127	2	1363	0.0737	
	2.4217	2	1362	0.0892			0.6716	2	1363	0.5110	
	1.7345	2	1362	0.1769			1.2278	2	1363	0.2933	
05:30	2.9741	2	1362	0.0514	Linear	06:00	1.1466	2	1363	0.3180	Linear
	1.8356	2	1365	0.1599			2.0493	2	1364	0.1292	
	1.2885	2	1365	0.2760			0.5584	2	1364	0.5723	
	3.9428	2	1365	0.0196			1.2333	2	1364	0.2917	
	0.1939	2	1365	0.8237			1.5228	2	1364	0.2185	
	1.0104	2	1365	0.3644			0.5044	2	1364	0.6040	
	1.9287	2	1365	0.1457			0.4198	2	1364	0.6573	
	1.3317	2	1365	0.2644			0.5281	2	1364	0.5899	
	0.0336	2	1365	0.9670			2.0858	2	1364	0.1246	
06:30	0.2846	2	1365	0.7524	Linear	07:00	1.8289	2	1364	0.1610	Linear
	0.3279	2	1365	0.7205			3.4698	2	1364	0.0314	
	2.9289	2	1364	0.0538			2.4817	2	1363	0.0840	
	1.6291	2	1364	0.1965			0.3945	2	1363	0.6741	
	3.2064	2	1364	0.0408			3.7250	2	1363	0.0244	
	1.3522	2	1364	0.2590			1.9854	2	1363	0.1377	
	4.6232	2	1364	0.0100			0.4010	2	1363	0.6697	
	2.4217	2	1364	0.0892			4.6585	2	1363	0.0096	
	6.5192	2	1364	0.0015			0.2390	2	1363	0.7875	
07:30	3.9361	2	1364	0.0197	Linear	08:00	0.0752	2	1363	0.9276	Non Linear
	2.2246	2	1364	0.1085			2.3996	2	1363	0.0911	
	2.2583	2	1364	0.1049			0.0654	2	1363	0.9367	
	1.4602	2	1364	0.2326			4.0141	2	1364	0.0183	
	0.6845	2	1364	0.5045			0.5974	2	1364	0.5504	
	5.6565	2	1364	0.0036			6.9629	2	1364	0.0010	
	1.1550	2	1364	0.3154			10.8088	2	1364	0.0000	
	0.5535	2	1364	0.5750			3.6502	2	1364	0.0262	
	1.7453	2	1364	0.1750			3.8672	2	1364	0.0211	
07:30	1.1324	2	1364	0.3226	Linear	08:00	7.1581	2	1364	0.0008	Non Linear
	6.6098	2	1364	0.0014			1.0707	2	1364	0.3431	
	0.4325	2	1364	0.6490			0.5811	2	1364	0.5594	
	4.2572	2	1364	0.0144			8.1377	2	1364	3.0674	

Jam	F	df1	df2	p-value	Ket	Jam	F	df1	df2	p-value	Ket
08:30	2.6504	2	1364	0.0710	Non linear	09:00	6.6555	2	1364	0.0013	Non Linear
	1.8312	2	1364	0.1606			6.7471	2	1364	0.0012	
	1.6264	2	1364	0.1970			3.0169	2	1364	0.0493	
	3.1040	2	1364	0.0452			0.6985	2	1364	0.4975	
	3.3157	2	1364	0.0366			2.0195	2	1364	0.1331	
	2.8007	2	1364	0.0611			4.1117	2	1364	0.0166	
	11.8068	2	1364	0.0000			0.0844	2	1364	0.9190	
	6.0840	2	1364	0.0023			0.6859	2	1364	0.5038	
	2.8442	2	1364	0.0585			4.4799	2	1364	0.0115	
09:30	7.3449	2	1364	0.0007	Linear	10:00	8.6259	2	1364	0.0002	Linear
	6.0034	2	1363	0.0025			0.0225	2	1363	0.9778	
	1.1444	2	1363	0.3187			0.1968	2	1363	0.8214	
	0.2708	2	1363	0.7628			4.1528	2	1363	0.0159	
	0.3076	2	1363	0.7353			0.7500	2	1363	0.4726	
	3.0426	2	1363	0.0480			5.8145	2	1363	0.0031	
	0.2938	2	1363	0.7455			2.7111	2	1363	0.0668	
	15.4381	2	1363	0.0000			0.8318	2	1363	0.4355	
	0.0535	2	1363	0.9480			2.2476	2	1363	0.1060	
10:30	3.9365	2	1363	0.0197	Non Linear	11:00	0.9304	2	1363	0.3946	Linear
	2.9868	2	1363	0.0508			13.1372	2	1363	0.0000	
	1.2821	2	1365	0.2778			1.0254	2	1364	0.3589	
	15.2572	2	1365	0.0000			0.2595	2	1364	0.7715	
	10.1286	2	1365	0.0000			4.9374	2	1364	0.0073	
	0.6674	2	1365	0.5132			8.8316	2	1364	0.0002	
	8.7842	2	1365	0.0002			0.3571	2	1364	0.6998	
	3.4615	2	1365	0.0317			7.9865	2	1364	0.0004	
	5.6658	2	1365	0.0035			1.7134	2	1364	0.1806	
11:30	0.6905	2	1365	0.5015	Non Linear	12:00	0.3234	2	1364	0.7238	Non Linear
	6.1918	2	1365	0.0021			1.3921	2	1364	0.2489	
	10.6683	2	1365	0.0000			6.8708	2	1364	0.0011	
	0.2366	2	1362	0.7894			3.3405	2	1362	0.0357	
	12.8820	2	1362	0.0000			3.3360	2	1362	0.0359	
	6.4575	2	1362	0.0016			5.5931	2	1362	0.0038	
	0.9272	2	1362	0.3959			5.1026	2	1362	0.0062	
	4.2523	2	1362	0.0144			3.8725	2	1362	0.0210	
	6.7734	2	1362	0.0012			3.5211	2	1362	0.0298	
11:30	3.0249	2	1362	0.0489	Non Linear	12:00	1.1020	2	1362	0.3325	Non Linear
	1.2705	2	1362	0.2810			11.1759	2	1362	0.0000	
	6.1301	2	1362	0.0022			1.9275	2	1362	0.1459	
	5.2164	2	1362	0.0055			11.9467	2	1362	0.0000	




Jam	F	df1	df2	p-value	Ket	Jam	F	df1	df2	p-value	Ket
12:30	4.4161	2	1365	0.0123	Linear	13:00	3.6706	2	1363	0.0257	Linear
	2.7109	2	1365	0.0668			0.5607	2	1363	0.5710	
	2.5891	2	1365	0.0755			1.2397	2	1363	0.2898	
	3.8649	2	1365	0.0212			0.8272	2	1363	0.4375	
	1.1926	2	1365	0.3038			0.2616	2	1363	0.7699	
	2.9664	2	1365	0.0518			4.3925	2	1363	0.0125	
	9.0230	2	1365	0.0001			0.9354	2	1363	0.3927	
	10.4279	2	1365	0.0000			5.9993	2	1363	0.0025	
	2.1860	2	1365	0.1128			0.2797	2	1363	0.7560	
13:30	0.5786	2	1365	0.5608	Non Linear	14:00	1.7030	2	1363	0.1825	Non Linear
	4.9359	2	1364	0.0073			12.3601	2	1363	0.0000	
	4.2158	2	1364	0.0150			7.0264	2	1363	0.0009	
	9.7009	2	1364	0.0001			3.1324	2	1363	0.0439	
	9.5846	2	1364	0.0001			4.3359	2	1363	0.0133	
	6.4632	2	1364	0.0016			1.5501	2	1363	0.2126	
	3.6689	2	1364	0.0258			4.9594	2	1363	0.0071	
	6.5627	2	1364	0.0015			0.9785	2	1363	0.3761	
	5.3158	2	1364	0.0050			4.6780	2	1363	0.0094	
14:30	5.5612	2	1364	0.0039	Linear	15:00	0.7343	2	1363	0.4800	Linear
	4.2781	2	1364	0.0141			0.5294	2	1363	0.5891	
	0.9275	2	1363	0.3958			2.4186	2	1363	0.0894	
	3.7839	2	1363	0.0230			2.3363	2	1363	0.0971	
	1.1000	2	1363	0.3332			7.4977	2	1363	0.0006	
	1.1674	2	1363	0.3115			1.0520	2	1363	0.3495	
	0.1609	2	1363	0.8514			7.6425	2	1363	0.0005	
	2.2051	2	1363	0.1106			0.4353	2	1363	0.6472	
	0.8502	2	1363	0.4276			5.8190	2	1363	0.0030	
15:30	2.7077	2	1363	0.0670	Linear	16:00	0.0125	2	1363	0.9875	Linear
	13.6129	2	1363	0.0000			0.0026	2	1363	0.9974	
	10.8967	2	1363	0.0000			5.2659	2	1363	0.0053	
	2.0303	2	1358	0.1317			2.7585	2	1360	0.0637	
	3.4140	2	1358	0.0332			8.8541	2	1360	0.0002	
	2.4810	2	1358	0.0840			4.1048	2	1360	0.0167	
	9.0485	2	1358	0.0001			1.7529	2	1360	0.1737	
	5.3975	2	1358	0.0046			0.2776	2	1360	0.7576	
	1.2891	2	1358	0.2758			3.9335	2	1360	0.0198	
	4.0975	2	1358	0.0168	Linear		0.2738	2	1360	0.7605	Linear
	2.1152	2	1358	0.1210			3.1574	2	1360	0.0429	
	1.6426	2	1358	0.1939			0.3526	2	1360	0.7029	
	0.9578	2	1358	0.3840			1.1271	2	1360	0.3243	

Jam	F	df1	df2	p-value	Ket	Jam	F	df1	df2	p-value	Ket
16:30	2.1159	2	1359	0.1209	Linear	17:00	2.6059	2	1362	0.0742	Linear
	1.7468	2	1359	0.1747			3.7139	2	1362	0.0246	
	4.5836	2	1359	0.0104			1.5082	2	1362	0.2217	
	5.5426	2	1359	0.0040			2.9852	2	1362	0.0509	
	5.7465	2	1359	0.0033			2.1471	2	1362	0.1172	
	1.4731	2	1359	0.2296			0.9940	2	1362	0.3703	
	0.6722	2	1359	0.5108			0.1086	2	1362	0.8971	
	5.3429	2	1359	0.0049			2.3918	2	1362	0.0919	
	0.1397	2	1359	0.8697			0.8686	2	1362	0.4198	
17:30	1.8014	2	1359	0.1655	Linear	18:00	0.0008	2	1362	0.9992	Linear
	0.4073	2	1364	0.6656			0.1095	2	1362	0.8963	
	2.0505	2	1364	0.1291			3.9058	2	1362	0.0204	
	1.0560	2	1364	0.3481			3.3313	2	1362	0.0360	
	2.1700	2	1364	0.1146			1.8527	2	1362	0.1572	
	0.0788	2	1364	0.9242			0.5727	2	1362	0.5641	
	0.3161	2	1364	0.7290			2.4100	2	1362	0.0902	
	0.4546	2	1364	0.6348			0.6879	2	1362	0.5028	
	1.1300	2	1364	0.3233			0.7431	2	1362	0.4758	
18:30	5.3166	2	1364	0.0050	Linear	19:00	1.4131	2	1362	0.2438	Linear
	7.2264	2	1364	0.0008			4.3459	2	1362	0.0131	
	1.7876	2	1363	0.1678			0.5273	2	1362	0.5903	
	5.2208	2	1363	0.0055			0.1344	2	1362	0.8743	
	0.1080	2	1363	0.8976			6.9368	2	1362	0.0010	
	2.2141	2	1363	0.1096			0.2401	2	1362	0.7866	
	5.0932	2	1363	0.0063			2.5359	2	1362	0.0796	
	0.0286	2	1363	0.9718			6.1508	2	1362	0.0022	
	0.0314	2	1363	0.9691			0.3908	2	1362	0.6766	
19:30	2.0525	2	1363	0.1288	Linear	20:00	2.0955	2	1362	0.1234	Linear
	2.0453	2	1363	0.1297			4.8640	2	1362	0.0079	
	0.7237	2	1363	0.4851			2.2377	2	1362	0.1071	
	0.1204	2	1361	0.8866			1.3860	2	1361	0.2504	
	0.4054	2	1361	0.6668			1.3575	2	1361	0.2577	
	4.3045	2	1361	0.0137			4.6643	2	1361	0.0096	
	0.0384	2	1361	0.9624			0.8133	2	1361	0.4436	
	0.8667	2	1361	0.4205			1.2208	2	1361	0.2953	
	1.1849	2	1361	0.3061			2.2129	2	1361	0.1098	
	0.2054	2	1361	0.8143	Linear		2.1427	2	1361	0.1177	Linear
	1.8491	2	1361	0.1578			2.2491	2	1361	0.1059	
	2.3338	2	1361	0.0973			3.0689	2	1361	0.0468	
	1.6993	2	1361	0.1832			1.1667	2	1361	0.3117	


Jam	F	df1	df2	p-value	Ket	Jam	F	df1	df2	p-value	Ket
20:30	0.6279	2	1360	0.5339	Linear	21:00	7.4391	2	1357	0.0006	Linear
	1.8782	2	1360	0.1533			0.2904	2	1357	0.7480	
	5.4756	2	1360	0.0043			0.0269	2	1357	0.9735	
	1.2467	2	1360	0.2878			1.9953	2	1357	0.1364	
	0.4849	2	1360	0.6159			4.1167	2	1357	0.0165	
	5.1661	2	1360	0.0058			1.9555	2	1357	0.1419	
	1.9008	2	1360	0.1499			2.9809	2	1357	0.0511	
	0.1116	2	1360	0.8944			0.2273	2	1357	0.7967	
	1.5915	2	1360	0.2040			2.3993	2	1357	0.0912	
	1.8194	2	1360	0.1625			1.7666	2	1357	0.1713	
21:30	2.5897	2	1357	0.0754	Linear	22:00	2.1436	2	1361	0.1176	Linear
	4.8491	2	1357	0.0080			3.4918	2	1361	0.0307	
	2.9800	2	1357	0.0511			0.4271	2	1361	0.6525	
	0.5386	2	1357	0.5837			0.2973	2	1361	0.7428	
	1.1902	2	1357	0.3045			0.4987	2	1361	0.6074	
	1.7871	2	1357	0.1678			0.8353	2	1361	0.4340	
	3.3705	2	1357	0.0347			3.2769	2	1361	0.0380	
	0.2169	2	1357	0.8051			1.6201	2	1361	0.1983	
	1.1901	2	1357	0.3045			2.7351	2	1361	0.0652	
	0.0374	2	1357	0.9632			1.2813	2	1361	0.2780	
22:30	2.2931	2	1361	0.1013	Linear	23:00	0.0633	2	1360	0.9387	Linear
	1.1954	2	1361	0.3029			3.5121	2	1360	0.0301	
	0.2439	2	1361	0.7836			0.2688	2	1360	0.7644	
	0.3833	2	1361	0.6817			1.7287	2	1360	0.1779	
	1.2156	2	1361	0.2969			0.1414	2	1360	0.8682	
	0.0809	2	1361	0.9223			1.4923	2	1360	0.2252	
	0.2673	2	1361	0.7655			3.3879	2	1360	0.0341	
	0.4971	2	1361	0.6084			3.4467	2	1360	0.0321	
	0.1821	2	1361	0.8335			1.3588	2	1360	0.2573	
	5.2094	2	1361	0.0056			0.0283	2	1360	0.9721	
23:30	5.5338	2	1361	0.0040	Linear	00:00	2.0988	2	1361	0.1230	Linear
	0.6825	2	1361	0.5055			0.7996	2	1361	0.4497	
	2.3317	2	1361	0.0975			0.8133	2	1361	0.4436	
	0.0073	2	1361	0.9928			1.1164	2	1361	0.3277	
	2.3546	2	1361	0.0953			5.3494	2	1361	0.0049	
	4.5139	2	1361	0.0111			0.3123	2	1361	0.7318	
	0.2594	2	1361	0.7715			2.5969	2	1361	0.0749	
	1.6239	2	1361	0.1975			0.7385	2	1361	0.4780	
	2.0876	2	1361	0.1244			1.2785	2	1361	0.2788	
	2.9799	2	1361	0.0511			2.3187	2	1361	0.0988	

**Lampiran 11** Arsitektur DNN Data Simulasi


- 00:30




- 01:00




- 01:30




- 02:00




- 02:30




- 03:00




- 03:30




- 04:00



- 04:30




- 05:00







- 05:30




- 06:00




- 06:30




- 07:00




- 07:30




- 08:00




- 08:30




- 09:00




- 09:30




- 10:00




- 10:30




- 11:00




- 11:30




- 12:00



- 12:30




- 13:00







- 13:30




- 14:00




- 14:30




- 15:00




- 15:30




- 16:00




- 16:30




- 17:00




- 17:30




- 18:00




- 18:30




- 19:00




- 19:30




- 20:00



- 20:30




- 21:00







- 21:30




- 22:00




- 22:30




- 23:00



- 23:30




- 24:00




**Lampiran 12** Arsitektur Hibrida ARIMAX-DNN Data Beban Listrik


- 00:30




- 01:00




- 01:30




- 02:00




- 02:30




- 03:00




- 03:30




- 04:00



- 04:30




- 05:00







- 05:30




- 06:00




- 06:30




- 07:00




- 07:30




- 08:00




- 08:30




- 09:00




- 09:30




- 10:00




- 10:30




- 11:00




- 11:30




- 12:00



- 12:30




- 13:00







- 13:30




- 14:00




- 14:30




- 15:00




- 15:30




- 16:00






- 16:30



- 17:00











- 20:30




- 21:00









- 22:30




- 23:00



- 23:30



- 24:00



**Lampiran 13** Perhitungan Horizon Data Beban Listrik

<b>Jam</b>	<b>Model</b>	<b>Short</b>	<b>Medium</b>	<b>Long</b>	<b>Average</b>
00:30	ARIMAX	100,97	143,21	158,07	134,08
	DNN	105,00	116,71	115,83	112,51
	Hibrida ARIMAX-DNN	104,25	135,36	150,36	129,99
01:00	ARIMAX	98,11	152,36	154,89	135,12
	DNN	100,59	114,94	112,60	109,38
	Hibrida ARIMAX-DNN	103,98	149,09	140,24	131,10
01:30	ARIMAX	96,24	152,01	152,66	133,64
	DNN	92,01	108,64	106,94	102,53
	Hibrida ARIMAX-DNN	91,56	142,39	134,37	122,77
02:00	ARIMAX	91,87	151,81	151,98	131,89
	DNN	89,64	112,43	115,18	105,75
	Hibrida ARIMAX-DNN	97,47	144,47	139,61	127,18
02:30	ARIMAX	92,98	159,11	154,00	135,36
	DNN	92,31	114,35	120,54	109,07
	Hibrida ARIMAX-DNN	69,89	151,26	133,16	118,10
03:00	ARIMAX	93,92	171,78	165,45	143,72
	DNN	91,48	125,78	131,14	116,13
	Hibrida ARIMAX-DNN	96,33	167,71	153,56	139,20
03:30	ARIMAX	95,23	202,84	187,53	161,87
	DNN	116,10	181,76	145,69	147,85
	Hibrida ARIMAX-DNN	89,02	200,78	165,95	151,92
04:00	ARIMAX	106,45	216,97	195,71	173,04
	DNN	123,23	196,17	153,56	157,65
	Hibrida ARIMAX-DNN	106,06	211,50	178,01	165,19
04:30	ARIMAX	112,64	182,69	172,07	155,80
	DNN	107,49	147,33	140,91	131,91
	Hibrida ARIMAX-DNN	112,54	172,39	155,86	146,93
05:00	ARIMAX	134,40	147,95	146,70	143,02
	DNN	147,62	91,84	96,29	111,92
	Hibrida ARIMAX-DNN	133,76	127,47	127,30	129,51
05:30	ARIMAX	159,22	151,99	145,27	152,16
	DNN	140,21	102,79	97,11	113,37
	Hibrida ARIMAX-DNN	154,35	136,81	128,06	139,74
06:00	ARIMAX	156,78	169,19	148,54	158,17
	DNN	125,82	128,99	118,24	124,35
	Hibrida ARIMAX-DNN	157,16	156,26	131,18	148,20

06:30	ARIMAX	134,92	147,00	125,40	135,77
	DNN	107,77	117,35	99,30	108,14
	Hibrida ARIMAX-DNN	128,36	138,46	111,86	126,23
07:00	ARIMAX	130,06	128,42	111,3	123,26
	DNN	118,18	104,39	89,44	104,00
	Hibrida ARIMAX-DNN	108,87	114,72	96,15	106,58
07:30	ARIMAX	135,26	135,63	117,76	129,55
	DNN	87,99	99,49	87,32	91,60
	Hibrida ARIMAX-DNN	102,90	128,81	110,28	114,00
08:00	ARIMAX	134,82	144,52	126,23	135,19
	DNN	107,89	100,81	90,05	99,58
	Hibrida ARIMAX-DNN	126,38	131,93	115,37	124,56
08:30	ARIMAX	142,83	152,5	132,78	142,70
	DNN	157,23	106,96	98,09	120,76
	Hibrida ARIMAX-DNN	144,82	138,16	123,00	135,33
09:00	ARIMAX	142,59	154,41	135,30	144,10
	DNN	145,54	115,48	102,61	121,21
	Hibrida ARIMAX-DNN	142,96	139,52	126,03	136,17
09:30	ARIMAX	159,45	159,18	140,52	153,05
	DNN	154,84	110,26	101,45	122,18
	Hibrida ARIMAX-DNN	169,81	141,95	131,41	147,72
10:00	ARIMAX	159,65	161,27	141,50	154,14
	DNN	147,69	115,97	103,58	122,41
	Hibrida ARIMAX-DNN	160,53	149,71	135,62	148,62
10:30	ARIMAX	158,86	163,85	145,91	156,21
	DNN	189,38	121,56	106,52	139,15
	Hibrida ARIMAX-DNN	160,07	147,29	136,87	148,08
11:00	ARIMAX	171,33	170,05	151,06	164,15
	DNN	181,53	134,28	115,10	143,64
	Hibrida ARIMAX-DNN	171,34	158,62	145,22	158,39
11:30	ARIMAX	164,36	171,78	154,23	163,46
	DNN	185,94	124,99	112,37	141,10
	Hibrida ARIMAX-DNN	165,08	160,29	148,42	157,93
12:00	ARIMAX	140,28	156,55	145,72	147,52
	DNN	170,46	116,96	107,32	131,58
	Hibrida ARIMAX-DNN	140,24	145,75	140,93	142,31
12:30	ARIMAX	138,07	155,13	145,79	146,33
	DNN	160,38	109,96	105,65	125,33
	Hibrida ARIMAX-DNN	124,73	131,02	123,07	126,27

13:00	ARIMAX	150,87	161,09	151,20	154,39
	DNN	162,20	113,31	106,83	127,45
	Híbrida ARIMAX-DNN	151,08	149,47	145,28	148,61
13:30	ARIMAX	150,32	169,10	157,38	158,93
	DNN	139,95	115,81	107,87	121,21
	Híbrida ARIMAX-DNN	160,82	149,51	148,73	153,02
14:00	ARIMAX	154,79	163,05	154,28	157,37
	DNN	146,04	112,78	104,67	121,16
	Híbrida ARIMAX-DNN	155,44	151,08	148,26	151,59
14:30	ARIMAX	149,05	155,21	148,89	151,05
	DNN	190,94	115,97	105,57	137,49
	Híbrida ARIMAX-DNN	149,61	143,12	142,73	145,15
15:00	ARIMAX	144,37	150,96	147,65	147,66
	DNN	187,46	117,90	107,76	137,71
	Híbrida ARIMAX-DNN	141,70	130,14	137,18	136,34
15:30	ARIMAX	144,89	156,18	150,84	150,64
	DNN	165,90	124,82	108,36	133,03
	Híbrida ARIMAX-DNN	144,71	138,69	142,00	141,80
16:00	ARIMAX	149,99	156,86	148,84	151,90
	DNN	167,27	133,25	111,90	137,47
	Híbrida ARIMAX-DNN	149,79	157,79	150,01	152,53
16:30	ARIMAX	162,30	144,31	142,35	149,65
	DNN	163,90	113,43	100,30	125,88
	Híbrida ARIMAX-DNN	162,37	128,73	134,87	141,99
17:00	ARIMAX	179,05	137,37	140,38	152,27
	DNN	199,71	127,99	113,35	147,02
	Híbrida ARIMAX-DNN	179,53	125,91	134,93	146,79
17:30	ARIMAX	178,17	156,66	160,94	165,26
	DNN	200,14	151,47	140,88	164,16
	Híbrida ARIMAX-DNN	178,64	149,71	157,31	161,89
18:00	ARIMAX	144,31	131,72	151,18	142,40
	DNN	134,05	133,24	130,75	132,68
	Híbrida ARIMAX-DNN	120,22	117,71	127,01	121,65
18:30	ARIMAX	106,30	138,5	151,01	131,94
	DNN	90,28	111,59	106,73	102,87
	Híbrida ARIMAX-DNN	108,47	119,58	129,17	119,07
19:00	ARIMAX	113,36	145,41	152,58	137,12
	DNN	122,21	101,79	99,80	107,93
	Híbrida ARIMAX-DNN	75,90	111,87	112,21	99,99

19:30	ARIMAX	100,84	146,58	152,1	133,17
	DNN	79,90	92,92	96,13	89,65
	Hibrida ARIMAX-DNN	84,41	120,17	123,66	109,41
20:00	ARIMAX	98,81	131,22	146,00	125,34
	DNN	100,19	98,18	97,48	98,62
	Hibrida ARIMAX-DNN	81,17	104,66	107,83	97,89
20:30	ARIMAX	97,60	145,31	157,35	133,42
	DNN	92,30	102,13	106,64	100,36
	Hibrida ARIMAX-DNN	79,56	124,31	121,41	108,43
21:00	ARIMAX	87,42	146,36	157,73	130,50
	DNN	86,11	111,53	119,18	105,61
	Hibrida ARIMAX-DNN	81,58	131,13	124,83	112,51
21:30	ARIMAX	82,21	146,53	154,66	127,80
	DNN	64,41	125,71	124,87	105,00
	Hibrida ARIMAX-DNN	100,09	134,20	126,93	120,41
22:00	ARIMAX	85,87	142,93	151,87	126,89
	DNN	73,81	126,96	120,95	107,24
	Hibrida ARIMAX-DNN	84,92	137,88	148,05	123,62
22:30	ARIMAX	83,83	151,02	156,71	130,52
	DNN	77,99	126,62	124,33	109,65
	Hibrida ARIMAX-DNN	85,08	141,46	140,29	122,28
23:00	ARIMAX	77,75	147,59	151,29	125,54
	DNN	80,26	121,74	116,34	106,11
	Hibrida ARIMAX-DNN	77,61	141,33	148,52	122,49
23:30	ARIMAX	74,70	143,36	145,22	121,09
	DNN	81,42	127,12	111,61	106,72
	Hibrida ARIMAX-DNN	65,12	135,36	128,97	109,82
00:00	ARIMAX	76,04	136,38	139,10	117,17
	DNN	92,47	119,03	108,02	106,51
	Hibrida ARIMAX-DNN	76,81	137,14	137,67	117,21

## Lampiran 14 Syntax ARIMAX

	D1	D2	D3	D4	D5	D6	D7	DV1	DV2	DV3	DV4	DV5	DV6	DV7	DV8	DV9	DV10	DV11	DV12	DV13	DV14	DV15	DV16	DV17	DV18	DV19	DV20	DV21;
data beban;																												
input y t																												
datalines;																												
2742.46	1			0			1		0		0		0		0													
	0			1			0		0		0		0		0													
	0			0			0		0		0		0		0													
	0			0			0		0		0		0		0													
	0																											
3009.85	2			0			0		1		0		0		0													
	0			0			0		0		0		0		0													
	0			0			0		0		0		0		0													
	0			0			0		0		0		0		0													
	0																											
3043.39	3			0			0		0		1		0		0													
	0			0			0		0		0		0		0													
	0			0			0		0		0		0		0													
	0			0			0		0		0		0		0													
	0																											
2950.09	4			0			0		0		0		1		0													
	0			0			0		0		0		0		0													
	0			0			0		0		0		0		0													
	0			0			0		0		0		0		0													
	0																											
.																												
.																												
.																												
.																												
.																												
.	1823			0			0		0		1		0		0													
	0			0			0																					



### Lampiran 14 Syntax ARIMAX (lanjutan)

```
.          1826      0      0      0      0      0      0
          1          0      0      0      0      0      0
          0          0      0      0      0      0      0
          0          0      0      0      0      0      0
          0
;
proc arima data = beban;
identify var=y(0) crosscorr=(t D1 D2 D3 D4 D5 D6 D7 DV1 DV2 DV3 DV4 DV5
DV6 DV7 DV8 DV9 DV10 DV11 DV12 DV13 DV14 DV15 DV16 DV17 DV18
DV19 DV20 DV21) nlag=49;
run;

estimate p=(1,2,3,4,5,6,7,10,11,15,17,46) q=(0) input=(t D1 D2 D3 D4 D5 D6 D7
DV1 DV2 DV3 DV4 DV5 DV6 DV7 DV8 DV9 DV10 DV11 DV12 DV13 DV14
DV15 DV16 DV17 DV18 DV19 DV20 DV21) noconstant
method=cls;
forecast out = beban lead=365 printall;
run;

proc univariate data=beban normal;
var residual;
run;

proc export data=work.beban
outfile='D:/Skripsi/analisis data asli/Arimax/arimax 2000.xls'
dbms=excel
replace;
run;
```

## Lampiran 15 Syntax DNN

```

install.packages("neuralnet")
install.packages("tseries")
install.packages("forecast")

library(neuralnet)
library(tseries)
library(forecast)

x<-read.csv("E:/firdha/dnn/data2000.csv",header = TRUE,sep=";")
zt<-as.ts(x)
ztrain<-as.ts(zt[1:1461,])
ztest<-as.ts(zt[1462:1826,])

z1t.std<-(ztrain[,1]-min(ztrain[,1]))/(max(ztrain[,1])-min(ztrain[,1]))

lagz1<-c(1,2,3,4,5,6,7,8,9,11,12,13,14,15,18,20,21,22,27,28,29,35,36,41,42,43)
maxlag<-max(lagz1)
laginput<-matrix(NA,(length(z1t.std)-maxlag),length(lagz1))

for (j in 1:length(lagz1))
{
  laginput[,j]<-z1t.std[(maxlag-lagz1[j]+1):(length(z1t.std)-lagz1[j])]
}
head(laginput)

data2000<-
data.frame(cbind(z1t.std[(maxlag+1):length(z1t.std)],laginput,zt[(maxlag+1):length(
z1t.std),-1]))
head(data2000)

rep1=2
h1<-c(1,2,3,4,5)
h2<-c(1,2,3,4,5)
neuron<-cbind(rep(h1,times=length(h2)),rep(h2,each=length(h1)))
n_fore=365
dummy1<-rbind((zt[(maxlag+1):length(z1t.std),-1]),ztest[, -1])

koef=list()
bestmodel=list()
fitsmodel=list()
foremodel=list()
akurasi=list()

```

## Lampiran 15 Syntax DNN (lanjutan)

```

for (k in seq_along(neuron[,1]))
{
  set.seed(k)
  best.model<-neuralnet(data2000[,1]~data2000[,2]+data2000[,3]+data2000[,4]+
    data2000[,5]+data2000[,6]+data2000[,7]+data2000[,8]+
    data2000[,9]+data2000[,10]+ data2000[,11]+data2000[,12]+
    data2000[,13]+data2000[,14]+data2000[,15]+data2000[,16]+
    data2000[,17]+data2000[,18]+data2000[,19]+data2000[,20]+
    data2000[,21]+data2000[,22]+data2000[,23]+data2000[,24]+
    data2000[,24]+data2000[,25]+data2000[,26]+data2000[,27]+
    t+D.1+D.2+D.3+D.4+D.5+D.6+D.7+
    DV1+DV2+DV3+DV4+DV5+

    DV6+DV7+DV8+DV9+DV10+DV11+DV12+DV13+DV14+DV15+DV16+DV17
    +

    DV18+DV19+DV20+DV21,data=data2000,hidden=neuron[k,],stepmax = 1e+08,
    rep=10,act.fct="logistic",linear.output = TRUE,likelihood=TRUE)

  plot(best.model, rep="best")
  mypath <- file.path("E:/firdha/dnn",paste("2000_", (k), ".jpg", sep = ""))
  png(file=mypath)
  plot(best.model, rep="best")
  dev.off()

  koef[[k]]<-best.model$weights[which.min(best.model$result.matrix[1,])]

  ytest<-c(data2000[,1],rep(0,n_fore))
  for (l in ((length(data2000[,1])+1):(length(data2000[,1])+n_fore)))
  {
    dummytest<-t(as.matrix(dummy1[l,]))
    lagtest<-matrix(0,1,length(lagz1))
    for (m in 1:length(lagz1))
    {
      lagtest[[m]]<-ytest[(l-lagz1[m])]
    }
    inputTest<-cbind(lagtest,dummytest)
    ytest[l]<-compute(best.model,covariate=inputTest,rep =
    which.min(best.model$result.matrix[1,]))$net.result
  }

```

## Lampiran 15 Syntax DNN (lanjutan)

```

fits.model<-
unlist(best.model$net.result[which.min(best.model$result.matrix[1,]))*(max(ztrain[
,1])-min(ztrain[,1]))+min(ztrain[,1])
  NtTrain<-(data2000[,1]*(max(ztrain[,1])-min(ztrain[,1]))+min(ztrain[,1]))-
(unlist(best.model$net.result[which.min(best.model$result.matrix[1,]))*(max(ztrain
[,1])-min(ztrain[,1]))+min(ztrain[,1]))
  avgNtTrain<-(abs(data2000[,1]*(max(ztrain[,1])-
min(ztrain[,1]))+min(ztrain[,1]))+abs(unlist(best.model$net.result)*(max(ztrain[,1])-
min(ztrain[,1]))+min(ztrain[,1])))/2
  RMSETrain<-((sum(NtTrain^2))/length(NtTrain))^(1/2)

sMAPE1<-c()
for (p1 in 1:length(NtTrain)){
  sMAPE1[p1]<-(1/length(NtTrain))*abs(NtTrain[p1])/avgNtTrain[p1]
}
sMAPETrain<-sum(sMAPE1)*100

fore.model<-
ytest[(length(data2000[,1])+1):(length(data2000[,1])+n_fore)]*(max(ztrain[,1])-
min(ztrain[,1]))+min(ztrain[,1])
  NtTest<-ztest[,1]-
(ytest[(length(data2000[,1])+1):(length(data2000[,1])+n_fore)]*(max(ztrain[,1])-
min(ztrain[,1]))+min(ztrain[,1]))
  avgNtTest<-
(abs(ztest[,1])+abs(ytest[(length(data2000[,1])+1):(length(data2000[,1])+n_fore)]*(
max(ztrain[,1])-min(ztrain[,1]))+min(ztrain[,1])))/2
  RMSETest<-((sum(NtTest^2))/length(NtTest))^(1/2)

sMAPE2<-c()
for (p2 in 1:length(NtTest)){
  sMAPE2[p2]<-(1/length(NtTest))*abs(NtTest[p2])/(avgNtTest[p2])
}
sMAPETest<-sum(sMAPE2)*100

fitsmodel[[k]]<-fits.model
foremodel[[k]]<-fore.model
akurasi[[k]]<-rbind(RMSETrain,RMSETest,sMAPETrain,sMAPETest)
}

write.csv(akurasi,"E:/firdha/dnn/akurasi2000.csv")
write.csv(fitsmodel,"E:/firdha/dnn/fits2000.csv")
write.csv(foremodel,"E:/firdha/dnn/fore2000.csv")
saveRDS(koef,file="E:/firdha/dnn/koef2000.rds")
readRDS(file="E:/firdha/dnn/koef2000.rds")

```

## Lampiran 16 Syntax Uji White

```
install.packages("tseries")
library(tseries)
x <- read.csv("E:/uji white/asli training.csv",sep = ";")
dummy<-read.csv("E:/uji white/dummy.csv",sep = ";")

#Uji White Pada 2000#
dm<-as.ts(dummy)
zt<-as.ts(x)
Z1<-zt[,40]
lagz1<-c(1,2,3,4,5,6,7,8,9,11,12,13,14,15,18,20,21,22,27,28,29,35,36,41,42,43)
maxlag<-max(lagz1)
laginputZ1<-matrix(NA,(length(Z1)-maxlag),length(lagz1))
for (j in 1:length(lagz1)){
  laginputZ1[j]<-Z1[(maxlag-lagz1[j]+1):(length(Z1)-lagz1[j])]}
head(laginputZ1)

data<-
data.frame(cbind(Z1[(maxlag+1):length(Z1)],laginputZ1,dm[(maxlag+1):length(Z1)
,]))
head(data)

ujiZ1=list()
statuji.Z1<-c()
p.Z1<-c()

for (i in 1:10)
{
  ujiZ1[[i]]<-white.test(data[,-1],data[,1],type="F")
  statuji.Z1[i]<-ujiZ1[[i]]$statistic
  p.Z1[i]<-ujiZ1[[i]]$p.value
}
hasilZ1<-cbind(statuji.Z1,p.Z1)
```

## Lampiran 17 Syntax Hibrida ARIMAX-DNN

```

install.packages("neuralnet")
install.packages("tseries")
install.packages("forecast")

library(neuralnet)
library(tseries)
library(forecast)

x<-read.csv("E:/firdha/hybrid/dataahybrid2000.csv",header = TRUE,sep=';')
zt<-as.ts(x)
ztrain<-as.ts(zt[1:1461,])
ztest<-as.ts(zt[1462:1826,])
at.train<-ztrain[,1]-ztrain[,2]

at.norm<--(at.train-min(at.train))/(max(at.train)-min(at.train))

lagz<-c(1,2,3,6,7,18,46)
maxlag<-max(lagz)
laginput<-matrix(NA,(length(at.norm)-maxlag),length(lagz))
for (j in 1:length(lagz))
{
  laginput[,j]<-at.norm[(maxlag-lagz[j]+1):(length(at.norm)-lagz[j])]
}
head(laginput)

data2000<-
data.frame(cbind(at.norm[(maxlag+1):length(at.norm)],laginput,zt[(maxlag+1):length(at.norm)],(3:dim(zt)[2]))))
head(data2000)

h1<-c(1,2,3,4,5)
h2<-c(1,2,3,4,5)
n_fore=365
neuron<-cbind(rep(h1,times=length(h2)),rep(h2,each=length(h1)))
dummy<-
rbind((zt[(maxlag+1):length(at.norm)],(3:dim(zt)[2]))),ztest[, (3:dim(ztest)[2])])

koef=list()
bestmodel=list()
fitsmodel=list()
foremodel=list()
akurasi=list()

```

## Lampiran 17 Syntax Hibrida ARIMAX-DNN (lanjutan)

```

for (k in seq_along(neuron[,1]))
{
  set.seed(k)
  best.model<-neuralnet(data2000[,1]~data2000[,2]+data2000[,3]+data2000[,4]+
    data2000[,5]+data2000[,6]+data2000[,7]+data2000[,8]+
    t+D1+D2+D3+D4+D5+D6+D7+DV1+DV2+DV3+DV4+DV5+
    DV6+DV7+DV8+DV9+DV10+DV11+DV12+DV13+DV14+DV15+DV16+DV17
    +
    DV18+DV19+DV20+DV21,data=data2000,hidden=neuron[k],
    stepmax = 1e+08,rep=10,act.fct="logistic",linear.output = TRUE,
    likelihood=TRUE)

  plot(best.model, rep="best")
  koef[[k]]<-best.model$weights[ which.min(best.model$result.matrix[1,])]
  plot2000<-file.path("E:/firdha/hybrid/plot", paste("eshyb2000_",(k),".jpg",sep=""))
  png(file=plot2000)
  plot(best.model, rep="best")
  dev.off()

  ytest<-c(data2000[,1],rep(0,n_fore))
  for (l in ((length(data2000[,1])+1):(length(data2000[,1])+n_fore)))
  {
    dummytest<-t(as.matrix(dummy[1,]))
    lagtest<-matrix(0,1,length(lagz))
    for (m in 1:length(lagz))
    {
      lagtest[[m]]<-ytest[(l-lagz[m])]
    }
    inputTest<-cbind(lagtest,dummytest)
    ytest[l]<-compute(best.model,covariate=inputTest,rep =
    which.min(best.model$result.matrix[1,]))$net.result
  }
  fits.model<-
  unlist(best.model$net.result[which.min(best.model$result.matrix[1,]))*(max(at.train)-min(at.train))+min(at.train)
  fits.ARIMAX_DNN<-
  ztrain[(maxlag+1):length(ztrain[,1]),2]+unlist(best.model$net.result[which.min(best.model$result.matrix[1,]))*(max(at.train)-min(at.train))+min(at.train)
  NtTrain<-(ztrain[(maxlag+1):length(ztrain[,1]),1])-
  (ztrain[(maxlag+1):length(ztrain[,1]),2]+(unlist(best.model$net.result)*(max(at.train)-min(at.train))+(min(at.train))))

```

## Lampiran 17 Syntax Hibrida ARIMAX-DNN (lanjutan)

```

avgNtTrain<-
(abs((ztrain[(maxlag+1):length(ztrain[,1]),1]))+abs((ztrain[(maxlag+1):length(ztrain
[,1]),2])+(unlist(best.model$net.result)*(max(at.train)-
min(at.train))+min(at.train)))))/2
RMSETrain<-((sum(NtTrain^2))/length(NtTrain))^(1/2)

sMAPE1<-c()

for (p1 in 1:length(NtTrain)){
  sMAPE1[p1]<-(1/length(NtTrain))*abs(NtTrain[p1])/avgNtTrain[p1]
}
sMAPETrain<-sum(sMAPE1)*100

fore.model<-
ytest[(length(data2000[,1])+1):(length(data2000[,1])+n_fore)]*(max(at.train)-
min(at.train))+min(at.train))
fore.ARIMAX_DNN<-
ztest[,2]+ytest[(length(data2000[,1])+1):(length(data2000[,1])+n_fore)]*(max(at.trai
n)-min(at.train))+min(at.train))
NtTest<-ztest[,1]-
(ztest[,2]+ytest[(length(data2000[,1])+1):(length(data2000[,1])+n_fore)]*(max(at.tra
in)-min(at.train))+min(at.train))
avgNtTest<-
(abs(ztest[,1])+abs((ztest[,2]+ytest[(length(data2000[,1])+1):(length(data2000[,1])+
n_fore)]*(max(at.train)-min(at.train))+min(at.train))))/2
RMSETest<-((sum(NtTest^2))/length(NtTest))^(1/2)

sMAPE2<-c()
for (p2 in 1:length(NtTest)){
  sMAPE2[p2]<-(1/length(NtTest))*abs(NtTest[p2])/avgNtTest[p2]
}
sMAPETest<-sum(sMAPE2)*100

fitsmodel[[k]]<- fits.ARIMAX_DNN
foremodel[[k]]<-fore.ARIMAX.DNN
akurasi[[k]]<-rbind(RMSETrain,RMSETest,sMAPETrain,sMAPETest)
}

write.csv(akurasi,"E:/firdha/hybrid/output/hyb_akurasi2000.csv")
write.csv(fitsmodel,"E:/firdha/hybrid/output/hyb_fits2000.csv")
write.csv(foremodel,"E:/firdha/hybrid/output/hyb_fore2000.csv")
saveRDS(koef,file="E:/firdha/hybrid/output/hyb_koef2000.rds")

```



## Lampiran 18 Surat Keterangan Pengambilan Data Surat

### SURAT KETERANGAN

Saya yang bertanda tangan di bawah ini menerangkan bahwa :

1. Mahasiswa Statistika FMKSD-ITS dengan identitas berikut :

Nama : Firdha Amelia Tryastuti

NRP : 06211440000075

Telah mengambil data di instansi/perusahaan kami :

Nama Instansi : PT. PLN (Persero) P2B-APB Jawa Tengah & DIY

Divisi/ bagian : Perencanaan dan Evaluasi (Renev)

sejak tanggal 8 Januari 2018 sampai dengan 12 Januari 2018 untuk keperluan Tugas Akhir Semester Genap 2017/ 2018.

2. Tidak Keberatan/Keberatan\* nama perusahaan dicantumkan dalam Tugas Akhir mahasiswa Statistika yang akan di simpan di Perpustakaan ITS dan dibaca di lingkungan ITS.
3. Tidak Keberatan/Keberatan\* bahwa hasil analisis data dari perusahaan dipublikasikan dalam E-journal ITS yaitu Jurnal Sains dan Seni ITS.

Ungaran 25 Juli 2018

Manajer

PT. PLN (Persero) P2B-APB

Jawa Tengah & DIY



M. Tresna Wikarsa

\*(coret yang tidak perlu)

*(halaman sengaja dikosongkan)*

## BIODATA PENULIS



Penulis dengan nama lengkap Firdha Amelia Tryastuti lahir di Kota Tegal pada tanggal 10 September 1996. Penulis menempuh pendidikan formal di SDN Keputran 6, SMPN 1 Salatiga, dan SMAN 1 Salatiga. Penulis diterima sebagai Mahasiswa Departemen Statistika ITS melalui jalur SBMPTN pada tahun 2014. Selama masa perkuliahan penulis aktif di beberapa organisasi dalam departemen yaitu Professional Statistics (PSt-HIMASTA ITS) dan unit kegiatan mahasiswa yaitu KSR PMI ITS. Selain itu semasa perkuliahan, penulis juga aktif di beberapa kegiatan kepanitiaan salah satunya menjadi Penanggung Jawab Region Semarang pada *Statistics Competition* (STATION) 2016 yang merupakan olimpiade statistika bagi siswa SMA dan sederajat. Apabila pembaca ingin memberi kritik dan saran serta diskusi lebih lanjut mengenai Tugas Akhir ini, dapat menghubungi penulis melalui email [firdhaameliat@gmail.com](mailto:firdhaameliat@gmail.com) atau nomor telepon 0856 4269 5080